

SVEUČILIŠTE U ZAGREBU  
PRIRODOSLOVNO - MATEMATIČKI FAKULTET  
MATEMATIČKI ODSJEK

Jelena Milardović

**SKLADIŠTENJE PODATAKA I POSLOVNA  
INTELIGENCIJA U TELEKOMUNIKACIJSKOJ  
INDUSTRIJI**

Diplomski rad

Zagreb, 2014. godina

SVEUČILIŠTE U ZAGREBU  
PRIRODOSLOVNO - MATEMATIČKI FAKULTET  
MATEMATIČKI ODSJEK

Jelena Milardović

**SKLADIŠTENJE PODATAKA I POSLOVNA  
INTELIGENCIJA U TELEKOMUNIKACIJSKOJ  
INDUSTRIJI**

Diplomski rad

Voditelj rada:  
Robert Manger

Zagreb, 2014. godina

Ovaj diplomski rad obranjen je dana \_\_\_\_\_ pred ispitnim povjerenstvom u sastavu:

1. \_\_\_\_\_ , predsjednik
2. \_\_\_\_\_ , član
3. \_\_\_\_\_ , član

Povjerenstvo je rad ocijenilo ocjenom \_\_\_\_\_ .

Potpisi članova povjerenstva:

1. \_\_\_\_\_
2. \_\_\_\_\_
3. \_\_\_\_\_

*Željela bih se zahvaliti svojim roditeljima i sestrama na razumijevanju i podršci tokom čitavog studiranja.*

*Luki koji je uvijek bio tu za mene i poticao me da ostvarim sve više i više ciljeve.*

*Svim mojim prijateljima i kolegama bez kojih ovo studiranje nebi bilo tako zabavno.*

*Posebno se želim zahvaliti svom mentoru prof.dr.sc Robertu Mangeru na vodstvu i pomoći pri izradi ovog diplomskog rada.*

## Sadržaj

1	PREDGOVOR.....	1
2	SKLADIŠTE PODATAKA.....	2
2.1	Uvod u skladištenje podataka .....	2
2.2	Definicija skladišta podataka.....	2
2.3	Arhitektura skladišta podataka .....	3
2.3.1	Pristup od vrha prema dolje.....	3
2.3.2	Pristup od dna prema gore .....	4
2.4	ETL proces .....	5
2.4.1	Dohvat podataka .....	6
2.4.2	Transformiranje podataka.....	6
2.4.3	Učitavanje podataka .....	7
2.5	Izazovi ETL procesa.....	9
2.6	Relacijske tablice .....	9
2.7	Činjenične tablice .....	11
2.8	Dimenzijsko modeliranje.....	12
2.8.1	Dimenzijske tablice .....	14
3	POSLOVNA INTELIGENCIJA.....	18
3.1	Uvod u poslovnu inteligenciju.....	18
3.2	Osnove poslovne inteligencije .....	19
3.2.1	Važnost točnosti podataka.....	19
3.3	Vrste poslovne inteligencije.....	20
3.3.1	Korporativno izvještavanje.....	20
3.3.2	Višedimenzionalna analiza - Kocka .....	20
3.3.3	Ad Hoc upiti i analiza .....	23
3.3.4	Statistička analiza i rudarenje podataka .....	23
3.3.5	Isporuka izvještaja krajnjim korisnicima i obavještavanje o kritičnim situacijama.....	25
3.4	Problemi i izazovi poslovne inteligencije .....	26
3.5	Primjene poslovne inteligencije.....	28
3.5.1	Analiza tržišta .....	28
3.5.2	Izvještaj za prodaju.....	29
3.5.3	Financijsko izvještavanje i analiza .....	29

4	PRIMJENA U TELEKOMUNIKACIJSKOJ INDUSTRIJI .....	31
4.1	Uvod .....	31
4.2	Kupac je u središtu pozornosti .....	31
4.3	Izazov telekomunikacijske industrije .....	32
4.4	Skladištenje podataka u telekomunikacijskoj industriji .....	33
4.4.1	Informacije o korisnicima .....	36
4.4.2	Izazovi i nedostaci skladištenja podataka .....	38
4.5	Poslovna inteligencija u telekomunikacijskoj industriji .....	39
4.5.1	Inteligentno vođenje korisnika .....	41
4.5.2	Upravljanje odnosima s korisnicima .....	41
4.5.3	Događaji u životu korisnika .....	42
4.5.4	Primjene poslovne inteligencije u telekomunikacijskoj industriji .....	43
5	TARIFNI KALKULATOR .....	46
5.1	Potreba za tarifnim kalkulatorom .....	46
5.2	Tarifni kalkulator i poslovna inteligencija .....	47
5.3	Izvedba tarifnog kalkulatora .....	48
6	ZAKLJUČAK .....	56
7	LITERATURA.....	57
8	SAŽETAK .....	58
9	SUMMARY .....	59
10	ŽIVOTOPIS .....	60

## 1 PREDGOVOR

Pravovremena i ispravna informacija najtraženija je roba današnjice u svim industrijskim granama. Svijet informacija neprestano se mijenja te onaj tko je u posjedu pravih informacija zapravo posjeduje pravo bogatstvo ako zna rukovoditi s njima.

Telekomunikacijska industrija je u prednosti nad ostalim industrijama jer posjeduje čitav niz informacija o korisniku. Oni znaju kako im se korisnik zove, gdje živi te koje usluge koristi. Sve te informacije bilježe se u telekomunikacijskim sustavima.

Pravo pitanje se postavlja već kod prvog pogleda na broj sustava koji upravljaju životom i uslugama korisnika. Sustavi su veliki, masovni i kompleksni. Kako rasporediti koja je informacija relevantna, a koja nije? Kada podatke možemo dohvatiti da ne opteretimo transakcijski sustav i ne ometamo njegov rad? Što napraviti kada naiđemo na neočekivane situacije koje opisuju korisnikov život?

Tema ovog rada je skladištenje podataka i poslovna inteligencija, te njena primjena i prednosti u telekomunikacijskoj industriji. Rad je podijeljen na 4 glavna dijela. Prvi se bavi skladištenjem podataka i opisuje proces prikupljanja podataka, promjene i punjenja u dimenzijski model podataka. Drugi se tiče poslovne inteligencije, odnosno, kako pravilno koristiti podatke koje smo prethodno doveli u našu bazu podataka. Treći dio pokazuje koncepte skladištenja podataka i poslovne inteligencije u telekomunikacijskoj industriji te ukazuje na prednosti korištenja ovakvog načina poslovanja. Rad završava praktičnim primjerom pod nazivom „Tarifni kalkulator“. Radi se o alatu koji pojednostavljuje rad prodajnih predstavnika. Izrađen je u sklopu ovog diplomskog rada pomoću jednog od najzanimljivijih programskih rješenja za poslovnu inteligenciju koji se trenutno nalaze na tržištu.

## 2 SKLADIŠTE PODATAKA

### 2.1 Uvod u skladištenje podataka

Razvoj telekomunikacijske industrije primarno za sobom povlači razvoj transakcijskih sustava. Najvažnije je osigurati korisniku dobru i postojanu uslugu, napraviti točnu naplatu potrošnje i omogućiti korisniku upravljanje uslugama koje su mu potrebne. S obzirom da je telekomunikacijska industrija jedna od najbrže rastućih industrija na svijetu, održavanje transakcijskih sustava na ovaj način dosta je težak zadatak. Rast telekoma podrazumijeva i povećanje broja korisnika, kao i povećano korištenje mreže i usluga koje pruža. Količina podataka koja se u tom trenutku generira je velika. Sve te podatke nije praktično držati u transakcijskim sustavima za cijeli period u kojem telekom posluje. Transakcijski sustavi imaju jedan cilj, a to je raditi ispravno i stabilno. Optimizirani su za svakodnevni rad i za očekivane operacije koje u svakom trenutku trebaju moći odraditi. S druge strane, za donošenje svih odluka potrebne su nam informacije. Koliko imamo korisnika, kakvi su financijski rezultati, koji prodajni kanal je najuspješniji - samo su neka od pitanja. Odgovore na ta pitanja, ravno iz transakcijskih sustava, ponekad nije moguće niti dobiti. U trenucima kada imamo sve potrebne podatke, dovodimo cjelokupno poslovanje u nezavidnu situaciju jer se baza podataka može vrlo lako usporiti. Iz tog razloga, logičan korak je izrada skladišta podataka. Tako odvajamo analitički sloj od svakodnevnog operativnog posla te osiguravamo dobar odziv za obje potrebe. Ovime se omogućava konsolidacija podataka s više izvora, povezivanje u zajedničku cjelinu i u konačnici, rast poduzeća na osnovu odluka temeljenih nad informacijama.

### 2.2 Definicija skladišta podataka

Najjednostavniji opis bio bi da skladište podataka upravlja podacima čak i izvan transakcijskih sustava. No, skladištenje podataka je puno složeniji proces. To je logičan skup informacija prikupljenih od mnogo različitih operativnih baza podataka. Pohranjuje povijesne informacije transakcijskih sustava u bazu podataka posebno dizajniranu za učinkovitu analizu velike količine podataka i njihovo izvještavanje. Skladište podataka može se smatrati kao kopija transakcijskih podataka posebno strukturirana za upite i



izvještavanje. Može se normalizirati ili denormalizirati ovisno o potrebama. U pozadini može se raditi o relacijskoj bazi podataka ili višedimenzionalnoj bazi podataka. Podaci u skladištu podataka često se mijenjaju te se skladišta podataka često moraju usredotočiti na određenu aktivnost ili entitet.

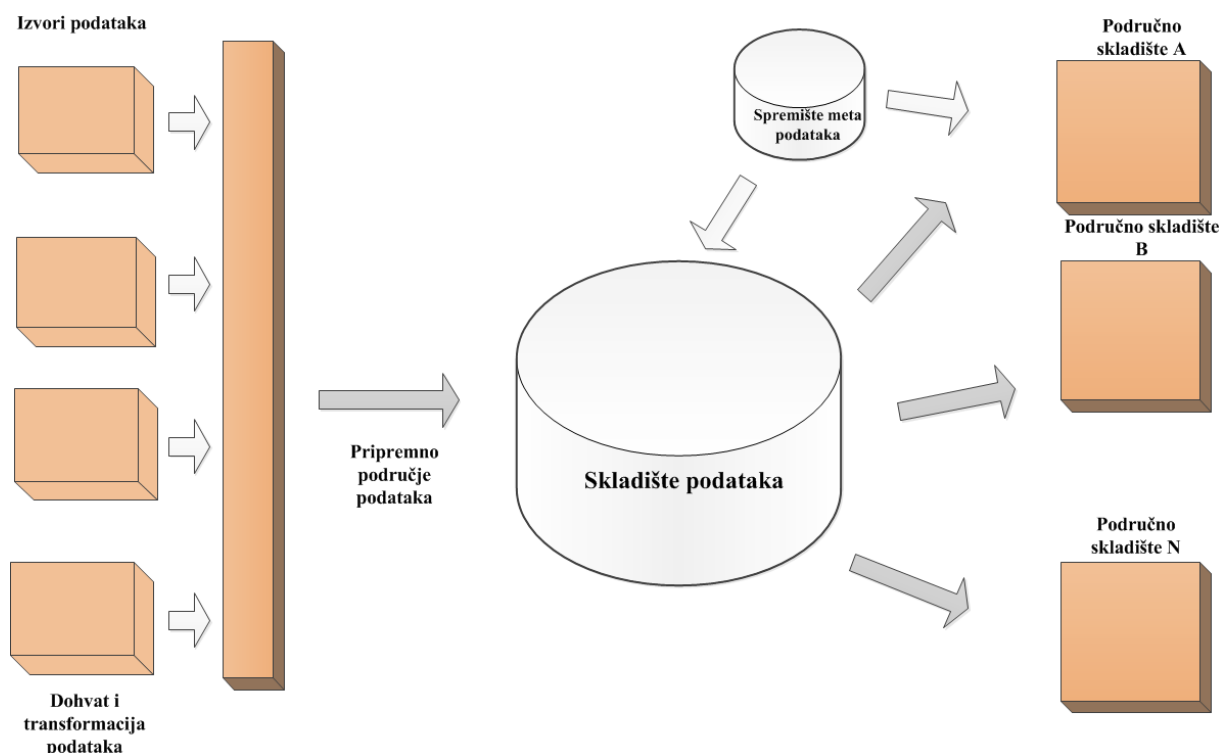
## 2.3 Arhitektura skladišta podataka

Postoje dva osnovna pristupa u arhitekturi skladišta podataka. To su:

- Od vrha prema dolje (eng. *Top - down*)
- Od dna prema gore (eng. *Bottom - up*)

### 2.3.1 Pristup od vrha prema dolje

Začetnik ovog pristupa je Bill Inmon. Prema njegovoj teoriji u skladištu podataka prevladavaju normalizirani modeli podataka te za pojedine grupe pitanja koje će krajnji korisnici često postavljati, kreiraju se mali dimenzijski modeli. Skladište podataka sadrži najdetaljnije, a područno skladište podataka sumirane podatke. No, ovakva izgradnja sustava je dugotrajna i skupa.

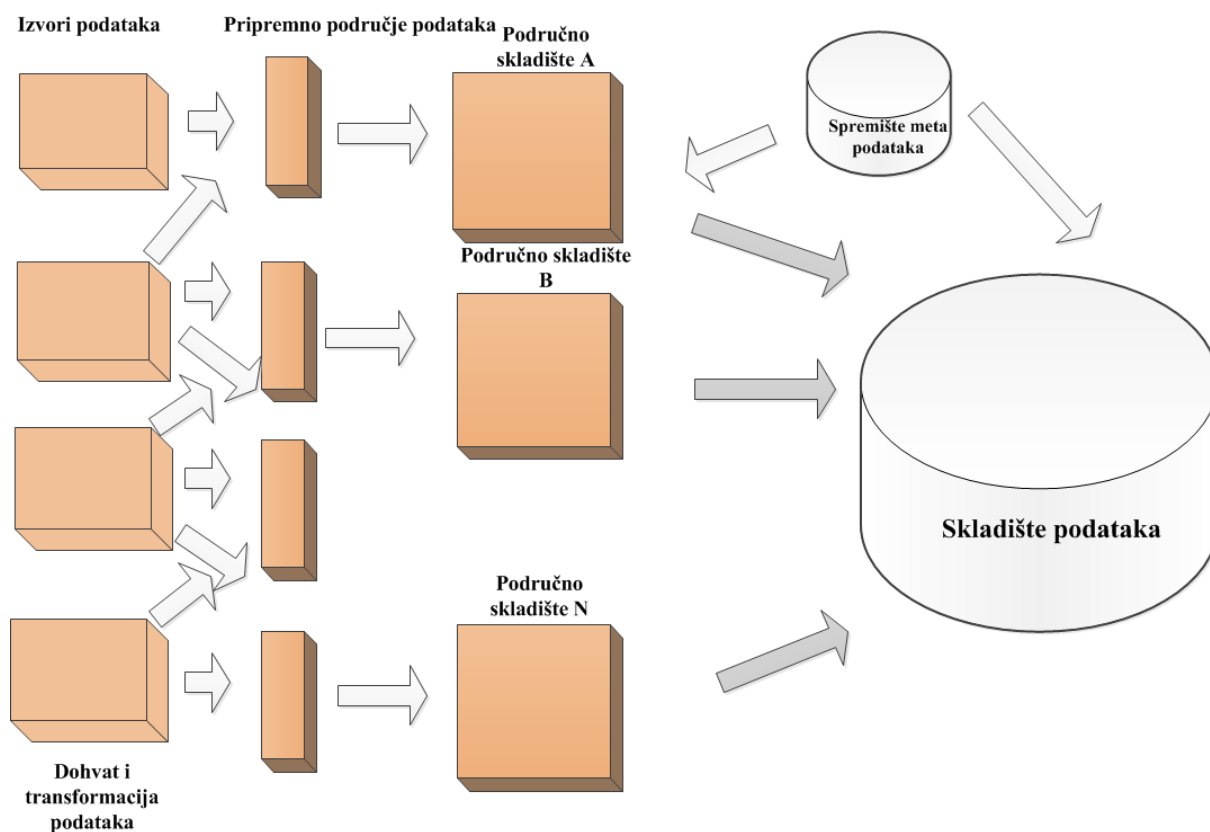


*Slika 1, Od vrha prema dolje pristup*

Na slici 1 je prikazan pristup od vrha prema dolje. Kao što je prikazano, iz izvora podataka prvo se dohvate i transformiraju svi podaci, a nakon toga se spremaju u skladište podataka. Iz skladišta podataka se ti podaci razdvajaju na područna skladišta. Takav pristup je dugotrajniji jer uzima sve podatke te ih sve transformira.

### 2.3.2 Pristup od dna prema gore

Začetnik ovog pristupa je Ralph Kimball te prema njegovoj teoriji skladišta podataka moraju biti razumljiva i brza. Kod ove arhitekture, područno skladište sadrži detaljne i povijesne podatke. Prednost je brza izgradnja sustava, no mana mu je da problem integracije sustava dolazi u središte pozornosti te je potrebno planirati zajednički razvojni okvir koji obuhvaća sve dijelove sustava skladištenja podataka.




*Slika 2, Od dna prema gore pristup*

Slika 2 prikazuje pristup od dna prema gore. Ovaj pristup dohvaća i transformira sve podatke, ali ih prvo sprema u područna skladišta pa tek ona u skladište podataka. Za razliku od pristupa od vrha prema dolje, ovaj pristup je brži jer ne sprema odmah sve podatke u skladište već ih dijeli.

## 2.4 ETL proces

Proces dohvata, transformiranja i učitavanja podataka (eng. *Extraction, Transformation and Loading*, ETL) je proces u skladištenju podataka koji uključuje vađenje podataka iz vanjskih izvora te ga učitava u skladište podataka. ETL je važan, kao što je i način na koji se podaci zapravo učitavaju.



*Slika 3. Proces pripreme podataka*

#### 2.4.1 Dohvat podataka

Dohvat podataka prvi je dio procesa koji rezultira izdvajanjem podataka iz izvornih sustava. Većina podataka se mora konsolidirati s različitih izvornih sustava. Svaki pojedini sustav može koristiti različitu organizaciju podataka. Dohvaćanje podataka objedinjuje podatke na jednom mjestu te ih konsolidira na način koji nam odgovara za daljnju obradu. Za kvalitetne podatke bitan je dohvat podataka. Izazovi s kojima se susrećemo u dohvat podataka su:

- Definiranje izvora podataka- transakcijski sustavi, aplikacije i strukture podataka
- Definiranje učestalosti dohvata podataka- dnevna, tjedna, mjesečna, itd.
- Definiranje vremenskog razdoblja- podaci prethodnog dana, prethodnog tjedna, itd.
- Definiranje redoslijeda izvršavanja dohvata podataka- određuje se treba li jedan proces dohvata podataka čekati drugi ili ne.

#### 2.4.2 Transformiranje podataka

Faza transformacije sadrži niz pravila ili funkcija za izvađen podatak. U svom izvornom obliku podaci nisu pogodni za učitavanje u skladište podataka. Neki izvori podataka zahtijevat će vrlo malo manipulacije podacima, no postoje podaci koji zahtijevaju kompleksne transformacije. Neke od najčešćih metoda transformacije su:

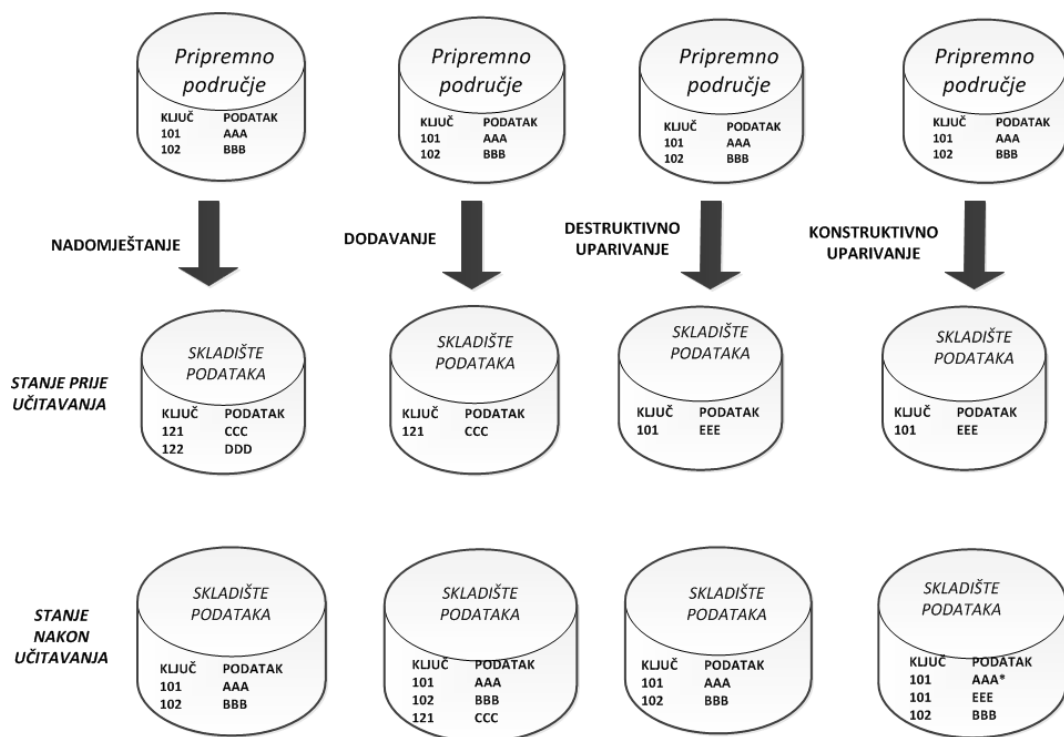
- Selekcija podataka – ovo je početak transformacije. Tu se odabiru zapisi ili dijelovi zapisa određenog sustava.
- Prilagodba formata podataka – promjena duljine i tipa podataka.
- Dekodiranje podataka – sređivanje podataka na vrijednosti razumljive krajnjem korisniku. Na primjer, podatak o spolu u jednom sustavu može biti označen s 1 i 2, za muški i ženski spol, dok u drugom sustavu s M i Ž.
- Razdvajanje podataka – odvajanje grupe podataka u posebnu cjelinu.
- Uklanjanje duplih podataka – brisanje duplih podataka. Ovo je potrebno napraviti jer je inače moguće dobiti krivu informaciju.

#### 2.4.3 Učitavanje podataka

U ovoj fazi podaci se učitavaju u skladište podataka. Neka skladišta podataka će samo prebrisati stare podatke s novim podacima. Složeniji sustavi mogu održavati povijesni trag i revizije svih promjena nad podacima. Ovdje se tri slučaja uvijek razmatraju, a to su: inicijalno učitavanje, inkrementalno učitavanje i potpuno osvježavanje.

Inicijalnim učitavanjem učitavamo sve podatke u skladište podataka prvi put. Nakon inicijalnog učitavanja, provodi se inkrementalno učitavanje gdje se periodički učitavaju samo novi podaci. Potpuno osvježavanje je slično inicijalnom učitavanju. Koristimo kad je potrebno skladište podataka ponovo napuniti podacima.

Postoje četiri metode učitavanja podataka u skladište podataka. To su učitavanje nadomještanjem, dodavanjem, destruktivnim uparivanjem i konstruktivnim uparivanjem. Na slici 4 prikazane su četiri metode učitavanja podataka u skladište podataka.



*Slika 4, Metode učitavanja podataka u skladište podataka*

**Nadomještanje.** Kada se podaci već nalaze u skladištu podataka, proces učitavanja briše postojeće te ih nadomješta podacima iz pripremnog područja. Ako podataka nema u skladištu podataka, proces učitavanja samo učitava podatke iz pripremnog područja. Ova metoda koristi se za inicijalno učitavanje ili potpuno osvježavanje kad je moguće učitati sve podatke odjednom u skladište podataka.

**Dodavanje.** Ova metoda učitava podatke bez utjecaja na postojeće podatke. Ovdje moramo paziti na duple podatke koji se mogu pojaviti. Takve podatke je potrebno odbaciti. Ova metoda koristi se za inicijalno učitavanje i potpuno osvježavanje kad nije moguće učitati podatke odjednom u skladište podataka.

**Destruktivno uparivanje.** Učitavaju se oni podaci gdje se vrijednost primarnog ključa ne podudara s vrijednošću ključa podataka u skladištu podataka. Ova metoda koristi se za inkrementalno učitavanje gdje nije bitno održavanje povijesti promjena podataka.

**Konstruktivno uparivanje.** Podaci se učitavaju bez obzira postoji li preklapanje u vrijednostima primarnih ključeva ili ne. Ova metoda koristi se za inkrementalno učitavanje gdje se želi očuvati povijest promjena podataka.

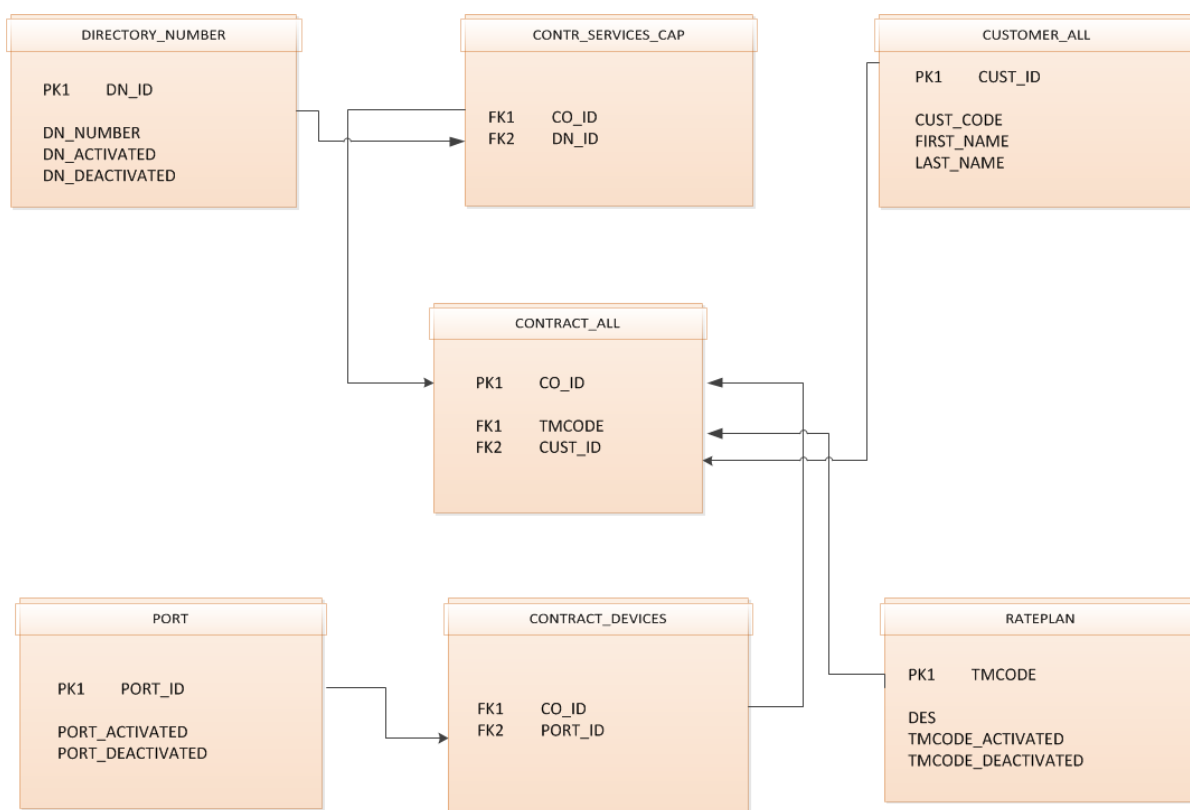
## 2.5 Izazovi ETL procesa

ETL procesi mogu biti vrlo složeni, a značajni operativni problemi mogu se pojaviti s nepropisno dizajniranim ETL sustavima. Raspon vrijednosti podataka ili kvalitete podataka u operativnom sustavu može biti izvan očekivanja. Vrijeme raspolaganja za izdvajanje podataka iz izvornih sustava može se promijeniti, što bi moglo značiti da se ista količina podataka mora obraditi u što manje vremena. Neki ETL sustavi moraju skalirati obradu terabajta podataka za ažuriranje skladišta podataka s desetaka terabajta podataka. Trebamo još pripaziti da su učitani relativno dosljedni. Dohvaćanje podataka s različitih izvornih sustava posljedično rezultira različitim ciklusima za ažuriranje. Neke od baza podataka mogu se obnavljati svakih nekoliko minuta, dok obnavljanje drugih potrajati nekoliko dana ili tjedana. ETL sustav može biti potreban dok svi izvori podataka nisu sinkronizirani.

## 2.6 Relacijske tablice

Osnovni element u relacijskom modelu podataka je relacija koja se može prikazati kao tablica gdje stupci predstavljaju attribute, a reci entitete. U relacijskim bazama podataka postoje primarni ključevi koji pomoći jednog ili više atributa jednoznačno definiraju redak u pojedinoj tablici. Također, s druge strane imamo i strane ključeve koji se sastoje od jednog ili više atributa te određuju vezu prema primarnim ključevima neke druge tablice. Ovi mehanizmi služe primarno za optimizaciju upita, ali i za jednostavan pregled baze i određivanje granulacije podataka u pojedinoj tablici.

Svaka relacija opisana je relacijskom shemom koja se odnosi na opis atributa koju sudjeluju u njoj s posebno naznačenim primarnim ključem. Relacije se koriste za spremanje opisa entiteta i njihovih odnosa. Na slici 5 prikazan je relacijski model podataka.



Slika 5, Relacijska tablica

Primarni ključ u tablici označen je sa PK, dok je strani ključ označen sa FK. U tablici RATEPLAN nalazi se primarni ključ TMCODE koji označava jedinstveni ID tarife, DES je opis tarife, dok atributi TMCODE\_ACTIVATED i TMCODE\_DEACTIVATED označavaju datum kad je određena tarifa aktivirana odnosno deaktivirana. Tablica CUSTOMER\_ALL ima primarni ključ CUST\_ID koji označava jedinstveni ID korisnika, a uz njega su tu atributi CUST\_CODE, FIRST\_NAME i LAST\_NAME koji označavaju redom broj korisnika, ime i prezime. Tablica DIRECTORY\_NUMBER kao primarni ključ ima DN\_ID koji je jedinstveni ID, te attribute DN\_NUMBER, DN\_ACTIVATED i DN\_DEACTIVATED koji redom označavaju korisnički broj (eng. *Mobile Station – ISDN Number, MSISDN*), datum aktivacije i deaktivacije broja. Tablica PORT kao primarni ključ ima PORT\_ID koji označava korisnikov IMSI, te attribute PORT\_ACTIVATED i PORT\_DEACTIVATED koji pokazuju kad je IMSI (eng. *International mobile Subscriber Identity*) aktiviran odnosno deaktiviran. Tablica CONTRACT\_ALL ima primarni ključ CO\_ID koji



označava jedinstveni ID korisničkog ugovora, te dva strana ključa, TMCODE i CUST\_ID. Tablica CONTR\_SERVICES\_CAP sadrži dva strana ključa CO\_ID i DN\_ID, dok tablica CONTRACT\_DEVICES sadrži CO\_ID i PORT\_ID koja u ovoj tablici imaju ulogu stranog ključa.

## 2.7 Činjenične tablice

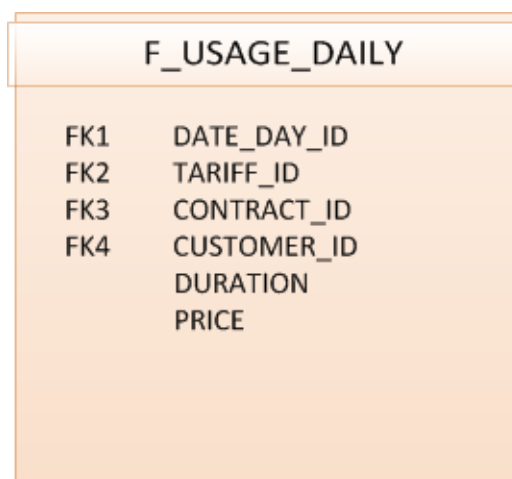
Svako skladište podataka sadrži barem jednu činjeničnu tablicu. Činjenične tablice su najveće tablice u skladištu podataka koje čine 90% njegovog zauzeća dok ostatak zauzimaju dimenzijske tablice. Činjenične tablice pohranjuju velik broj zapisa jer se često radi o povijesnim podacima. Ono što definira činjeničnu tablicu je razina detalja ili zrnatost detalja. Razlikujemo nižu i višu zrnatost detalja. Niža zrnatost znači više detalja, dok viša zrnatost manje detalja kod prikaza podataka. Problem koji se javlja kod podataka niže zrnatosti je taj da ih je teže održavati zbog njihovog velikog broja. S druge strane, podaci više zrnatosti zauzimaju manje diskovnog prostora te je lakše njihovo održavanje. Nedostatak podataka više zrnatosti je gubitak detaljnih podataka, tako da je pri oblikovanju skladišta podataka preporučeno da su činjenične tablice najniže zrnatosti.

Činjenična tablica središnja je točka dimenzijskog modela podataka koja sadrži mjere i dimenzijske ključeve. Mjere predstavljaju sve što se može analizirati. Potpuno aditivne mjere su najkorisnije mjere u činjeničnoj tablici jer se mogu agregirati po svim dimenzijama bez ikakvog ograničenja. Postoje i djelomično aditivne mjere koje se mogu djelomično agregirati, te neaditivne mjere koje se ne mogu agregirati po niti jednoj dimenziji. Uz mjere, u činjeničnoj tablici nalaze se i dimenzijski ključevi. To su strani ključevi prema dimenzijama pomoću kojih se analiziraju mjere.

Kao što je spomenuto, kod oblikovanja skladišta podataka preporučeno je da su činjenične tablice najniže zrnatosti, no izvođenje upita na takvoj tablici je iznimno sporo. Najbolji način da se znatno poboljšaju performanse upita je uvođenje agregacijskih tablica. Agregacijske tablice su izvedenice činjeničnih tablica više zrnatosti koja se postiže izostavljanjem nekih dimenzija te su tako upiti brži i do nekoliko tisuća puta. Da bi se spriječio nekontrolirani rast činjeničnih tablica najniže zrnatosti, potiče se korištenje

agregacijskih tablica. Vrijeme je najčešći kriterij agregiranja jer možemo podatke skladištiti na mjesečnoj, kvartalnoj ili godišnjoj razini.

Osnovna struktura činjenične tablice prikazana je na slici 6.



Slika 6, Činjenična tablica

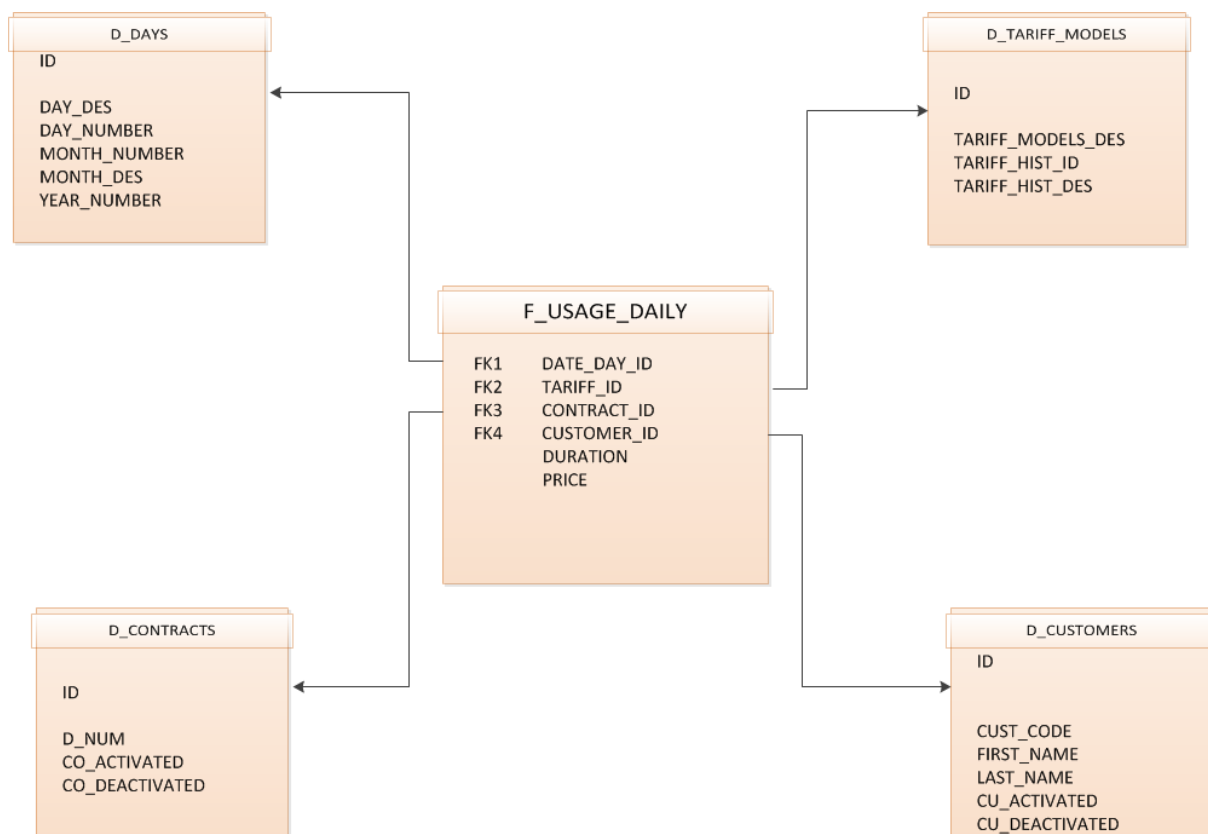
Činjenična tablica F\_USAGE\_DAILY sastoji se od četiri dimenzijska ključa za dane, tarife, ugovore i korisnike te od dvije mjere za iznos cijene i duljine poziva.

## 2.8 Dimenzijsko modeliranje

Dimenzijsko modeliranje je tehnika oblikovanja skladišta podataka. Ideja je da se svaki poslovni proces može vizualizirati kao višedimenzionalna kocka. Kako je dimenzijski model intuitivan, a pruža dobre performanse upita, dimenzijsko modeliranje pokazalo se kao glavna tehnika skladištenja podataka. Svaki dimenzijski model sastoji se od činjenične tablice u kojoj se nalaze strani ključevi prema dimenzijskim tablicama. Ovisno jesu li dimenzijske tablice normalizirane ili denormalizirane, razlikujemo dva tipa podataka, zvjezdasti i pahuljičasti.

**Zvjezdasti model.** Zvjezdasti model koristi se kad je dimenzijska tablica denormalizirana. Takav model podataka sporije se puni podacima transakcijskog sustava.

Zvezdasti model ima jednostavnu i korisniku razumljivu strukturu te ima jako brz odziv na upite zbog manjeg broja spajanja tablica.




*Slika 7, Zvezdasti dimenzijski model*

Na slici 7 prikazan je primjer zvjezdastog dimenzijskog modela podataka kojim je oblikovan dio skladišta podataka za dnevnu potrošnju. Model se sastoji od činjenične tablice koja se veže na denormalizirane dimenzije dana, ugovora, tarifnog modela i korisnika.

**Pahuljičasti model.** Pahuljičasti model se koristi za normalizirane dimenzijske tablice pa je ovaj model sličniji modelu entitet-veza. Atributi niske kardinalnosti se izdvajaju iz inicijalnih dimenzijskih tablica u dodatne dimenzijske tablice, te se nadomještavaju sa stranim ključem prema primarnom ključu novonastale dimenzijske tablice. Prednost pahuljičastog modela jest da normalizirane dimenzijske tablice iziskuju manje prostora

od denormaliziranih, no kako dimenzijske tablice ionako zauzimaju malo prostora, to je tek neznatna prednost pahuljičastog modela podataka. Pahuljičasti model podataka očituje se u strukturi koja se lakše prilagođava promjenama korisničkog zahtjeva te u bržem učitavanju zapisa iz transakcijskih sustava. Pahuljičasti model je manje zastupljeniji jer su performanse upita lošije zbog spajanja većeg broja tablica.



Slika 8, Pahuljičasti dimenzijski model

Na slici 8 prikazan je dio skladišta za dnevnu potrošnju, ali je sad oblikovan pahuljičastim dimenzijskim modelom podataka.

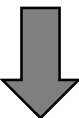
### 2.8.1 Dimenzijske tablice

Dimenzijske tablice su male obzirom na prostorno zauzeće i sadrže relativno statičke podatke. Prema učestalosti promjena dimenzije dijelimo na sporomijenjajuće i

brzomijenjajuće. Sporomijenjajuće tablice su zastupljenije te ih razlikujemo prema načinu praćenja povijesti promjena.

**Sporomijenjajuće dimenzije tipa 1.** Ove tablice se koriste kad pri promjenama dimenzijskih atributa stare vrijednosti nisu od značaja ili ih možemo zanemariti. Nova vrijednost atributa trajno nadomješta staru te je time izgubljena i povijest promjena dimenzijskog atributa. Promjene atributa ne utječu na primarne ključeve.


ID	CUST_ID	FIRST_NAME	LAST_NAME	STREET
1	A123	Ivan	Horvat	Nehajska_3


postaje

1	A123	Ivan	Horvat	Sokolgradska_17
---	------	------	--------	-----------------

**Sporomijenjajuće dimenzije tipa 2.** Sporomijenjajuće dimenzije tipa 2 predstavljaju primarnu tehniku praćenja povijesti promjena dimenzijskih atributa. Ovdje dolazi do izražaja uporaba surogatnih primarnih ključeva jer pri praćenju promjena se ne smiju mijenjati vrijednosti primarnih ključeva. Promjena se ne manifestira ažuriranjem atributa već stvaranjem novog zapisa u dimenzijskoj tablici. Tom zapisu dodjeljuje se nova vrijednost surogatnog primarnog ključa. Negativna strana ove tehnike je povećanje diskovnog prostora do kojeg može doći stvaranjem novih dimenzijskih zapisa zbog čestih promjena dimenzijskih atributa.

ID	CUST_ID	FIRST NAME	LAST NAME	STREET	VALID FROM	VALID TO	FLAG
1	A123	Ivan	Horvat	Nehajska_3	10.02.2007. 11:32:43	17.12.2013. 19:23:32	N




postaje

1	A123	Ivan	Horvat	Sokolgradska_17	17.12.2013. 19:23:34	01.01.3000. 00:00:00	Y
---	------	------	--------	-----------------	-------------------------	-------------------------	---

**Sporomijenjajuće dimenzije tipa 3.** Ove tablice se koriste kad je važno pored trenutne vrijednosti dimenzijskog atributa istovremeno održati i njegovu prethodnu vrijednost. Primjenjuju se u situacijama kad pri promjeni dimenzijskih atributa postoji potreba za većim brojem interpretacija istih podataka.


	CUST_I	FIRST_NAM	LAST_NAM		
ID	D	E	E	STREET	STREET_OLD
1	A123	Ivan	Horvat	Nehajska_3	



postaje

1	A123	Ivan	Horvat	7	Sokolgradska_1 Nehajska_3
---	------	------	--------	---	------------------------------

**Brzomijenjajuće dimenzije.** Ovakve tablice nisu rijetkost u skladištu podataka gdje je učestala promjena dimenzijskih atributa. No, ovdje se susrećemo sa problemom ako se želi pratiti povijest promjena njenih atributa. Uvodi se jedna ili više minidimenzija u koje se izdvajaju dimenzijski atributi koji su zanimljivi za praćenje, a u originalnoj tablici ostavljaju se atributi za koje nije bitno praćenje povijesti promjena i za koje je važno samo da sadržavaju trenutne vrijednosti. Nedostatak koji se ovdje javlja je otežan pregled svih atributa. Rješenje je da se uvede strani ključ u originalnoj dimenziji prema trenutnom zapisu minidimenzija, te se tako izbjegne spajanje dimenzija preko činjenične tablice. Takav način oblikovanja dimenzijskih tablica naziva se dopuštena normalizacija.



*Slika 9, Brzomijenjajuća dimenzija korisnika*

Na slici 9 prikazano je oblikovanje brzomijenjajuće dimenzije korisnika D\_CUSTOMERS. Iz originalne dimenzijske tablice D\_CUSTOMERS izdvojeni su dimenzijski atributi ugovora korisnika u dimenziju D\_CUSTOMER\_CONTACTS. Nakon ovog, činjenična tablica F\_TABLE ima dva strana ključa, jedan prema dimenziji D\_CUSTOMERS, a drugi prema dimenziji D\_CUSTOMER\_CONTACTS.

## 3 POSLOVNA INTELIGENCIJA

### 3.1 Uvod u poslovnu inteligenciju

Inteligencija je sposobnost učenja, razumijevanja te pristupanja novoj situaciji. Poslovnu inteligenciju možemo opisati kao uzimanje sirovih podataka te pretvaranje tih podataka u korisne informacije na temelju kojih mogu biti bazirani poslovni slučajevi. To je pojam koji objedinjuje rudarenje podataka, statističke analize, predviđanja te potporu u odlučivanju. Poslovna inteligencija je poslovna strategija usmjerena prema predviđanju i razumijevanju potreba poduzeća. To je nauka o korisnicima, konkurentima, poslovnim partnerima i o svom internom poslovanju.

Pojam poslovna inteligencija ima različito značenje kod različitih ljudi, no u globalu ukratko znači opisati sve od operativnog izvješća do rudarenja podataka. Poslovna inteligencija uključuje:

- Sustav za podršku u predviđanju
- Skladište podataka za izvještavanje
- Statističke analize
- Izvještaje
- Višedimenzionalnu analizu
- Ah hoc upite

Poslovna inteligencija je pojam koji se možda najčešće koristi, ali je neshvaćen pojam u tehnologiji. Za poslovne menadžere, poslovna inteligencija je informacija koja im pomaže u poslovanju. Metode kojima su ti izvještaji stvoreni su obično proračunske tablice i prezentacije. Mnogi odjeli unutar organizacije koriste izvješća i ostale alate poslovne inteligencije. Neki od odjela su upravljanje odnosima s korisnicima, prodaja, računovodstvo te drugi.

Jedna organizacija analizira samo deset posto prikupljenih podataka. Poslovna inteligencija je način kako iskoristiti preostalih devedeset posto.

Prednosti poslovne inteligencije su poboljšana poslovna učinkovitost i produktivnost, poboljšani poslovni odnosi, povećana je poslovna vrijednost i smanjenje troškova.



## 3.2 Osnove poslovne inteligencije

Bitna stavka za uspjeh modernog poduzeća je njegova sposobnost iskoristiti sve dostupne informacije. Posljednjih par godina došlo je do eksplozije informacija. Podaci postaju sve složeniji, no ti podaci su korisni samo ako organizacija ima sustave i alate da pretvori podatak u korisnu informaciju. Danas je informacija izvor snage organizacije, što brže teče, to će bolje biti poslovanje.

Podatak je pojedinačna sirova činjenica izvan konteksta, nema neko značenje te ga je teško razumjeti. Podaci u kontekstu su činjenice koje imaju neko značenje i mogu se razumjeti.

Informacije su skup podataka u smislu da se odnosi na jedan ili više entiteta u vremenu. Skup podataka u kontekstu je poruka koja postaje samo informacija kada netko prihvati tu poruku te je ona relevantna za njegove potrebe. Informacije moraju imati važnost i vremenski okvir.

Poslovna inteligencija ima tri značajke:

- To je proces prikupljanja podataka i informacija
- Usmjerena je na informacije pomoću kojih se mogu predvidjeti budući procesi, događaji ili akcije
- Instrument koji ima potpunu ulogu u procesu donošenja odluka.

### 3.2.1 Važnost točnosti podataka

Alati poslovne inteligencije su dobri onoliko koliko su dobri podaci koji se koriste. Netočni podaci štete poslu, te mogu trošiti marketinške resurse i štetiti organizaciji. Podatak je najvažniji materijal za poslovne analize te je realna opasnost netočan podatak. Organizacija koja igra na kartu nove poslovne strategije s netočnim podacima može učiniti sebi nepopravljivu štetu. Činjenica je da netočni podaci vode do netočnih zaključivanja, a to vodi do ugrožavanja organizacijske strategije. Studija od strane instituta za skladištenje podataka procjenjuje da poduzeća gube više od 611 milijardi dolara svake godine zbog netočnih podataka. Podaci mogu postati netočni na više načina. Oni putuju preko aplikacija i baza podataka, a to ne predstavlja samo vrijednost, već i

rizik. Broj puta koliko se podatak preselio s jednog sustava u drugi obrnuto je proporcionalan njegovoj kvaliteti.

Podaci također mogu biti nepotpuni ili zastarjeli. Mogu se izvaditi iz konteksta, namjerno ili slučajno. Da bi se zadržala pouzdanost podataka, potrebno je pratiti tehnike, metode i procese i poduzeti određene mjere za poboljšanje konzistentnosti podataka.

### 3.3 Vrste poslovne inteligencije

Poslovna inteligencija pruža informacije mnogim korisnicima, kao na primjer, kako smanjiti troškove, povećati produktivnost ili prihod. Poslovna inteligencija veoma se razvijala posljednjih deset godina. Danas poslovna inteligencija nastavlja rasti još većim tempom jer su organizacije počele shvaćati da što prije isporuče podatke, to će brže razviti konkurentsku prednost.

Vrste poslovne inteligencije uključuju korporativno izvještavanje, analizu kocke, ad hoc upite i analize, statističke analize i rudarenje podataka, obavještanje u kritičnim situacijama, te pravovremenu dostavu izvještaja.

#### 3.3.1 Korporativno izvještavanje


Korporativno izvještavanje je najčešći tip poslovne inteligencije. Kad poduzeće želi raspodijeliti standardna operativna ili financijska izvješća koristi se korporativnom izvještavanjem. Ono mora biti dizajnirano za korisnike na svim razinama u poduzeću. Organizacije su pronašle jasna vraćanja na njihova ulaganja u operativna i financijska izvještavanja. Jedna od najdominantnijih značajki svakog poslovnog izvještavanja je njegova sposobnost da proizvede vrlo fleksibilna formatirana izvješća tako da podaci budu predstavljeni u obliku u kojem ga većina razumije.

#### 3.3.2 Višedimenzionalna analiza - Kocka

Dugi niz godina poduzeća spremaju višedimenzionalne podatke, pomoću zvjezdaste ili pahuljaste sheme u relacijskim bazama podataka. Tijekom vremena, u relacijske baze podataka dodane su optimizacije koje poboljšavaju upite na ovim shemama. Online analitička obrada podataka (eng. *Online analytical processing*, OLAP) je vrsta obrade

podataka koja daje brzi odgovor na višedimenzijske upite. Naziv koji se još koristi za OLAP je „kocka“.

To je dio šire kategorije poslovne inteligencije, što uključuje i ETL, relacijska izvještavanja i rudarenje podataka. OLAP uzima kopiju skupa izvora podataka i restrukturira ih u OLAP kocke. Za složene upite OLAP može dati odgovor za oko 0.1 posto vremena za isti upit u transakcijskim relacijskim bazama podataka. Kocka se stvara iz zvjezdaste sheme tablica. U središtu se nalazi činjenična tablica u kojoj se navode temeljne činjenice koje čine upit. Ove tablice pokazuju kako se nagomilavanje relacijskih podataka može analizirati. Zbog potencijalno velikog broja izračuna agregacije često se samo unaprijed određen broj u potpunosti obračunava, a ostali su riješeni na zahtjev.



*Slika 10, primjer kocke*

Na slici 10 prikazan primjer kocke sa dimenzijama korisnika, dana i tarifa. Postoje tri vrste OLAP-a te svaka od njih ima određene prednosti.

### 3.3.2.1 Višedimenzijski OLAP

Višedimenzijski OLAP (eng. *Multidimensional OLAP*, MOLAP) je klasični oblik OLAP-a i ponekad se naziva samo OLAP. MOLAP je tip OLAP-a kod kojeg se podaci pohranjuju i višedimenzijsko skladište podataka. MOLAP se najviše koristi za gusto popunjene kocke, gdje većina ćelija sadrži vrijednost. Gustoća kocke definira se kao omjer ukupnog broja ćelija popunjenih s vrijednošću i ukupnog mogućeg broja ćelija u kocki. Što je omjer bliži jedinici, to je kocka gušće popunjena. Prednost MOLAP-a je brzina odziva na upit. Obzirom da je potrebno vrijeme da se kocka izgradi, izazov je latencija podataka. MOLAP je bolji na manjim skupovima podataka jer brzo vraća odgovor, a treba mu manje prostora za pohranu.

### 3.3.2.2 Relacijski OLAP

Relacijski OLAP (eng. *Relational OLAP*, ROLAP) radi izravno s relacijskim bazama podataka za pohranu podataka. Podaci su pohranjeni u relacijskom dijelu skladišta podataka i dohvaćaju se SQL (eng. *Structured Query Language*) upitima. Nove tablice su stvorene da sadrže prikupljene informacije. Kako kod ROLAP-a podaci nisu agregirani, prilikom svakog upita provodi se njihova agregacija, što negativno utječe na brzinu upita. ROLAP je idealan za rijetko popunjene kocke gdje bi se korištenjem MOLAP-a zauzelo puno više diskovnog prostora.

### 3.3.2.3 Hibridni OLAP (HOLAP)

Hibridni OLAP (eng. *Hybrid OLAP*, HOLAP) je posebna vrsta OLAP-a gdje su podaci pohranjeni i u relacijskoj bazi i u višedimenzijskom spremištu podataka. Dakle, tu se kombiniraju najbolje karakteristike MOLAP-a i ROLAP-a. Na primjer, detaljni podaci mogu se nalaziti u relacijskom dijelu skladišta podataka, a agregirani u višedimenzijskom spremištu podataka. Mana ovog sustava je veća kompleksnost, no prednosti su sve one koje dolaze s MOLAP-om i ROLAP-om.

Višedimenzijska analiza je vrsta poslovne inteligencije idealna za osnovne analize koje se mogu predvidjeti. Višedimenzijskom analizom analiziramo ograničene skupove podataka, ciljano za analitičare i druge korisnike koji trebaju sigurno i jednostavno okruženje za osnovno istraživanje podataka unutar ograničenog raspona

podataka. Ova analiza omogućuje ljudima da prođu kroz izvješća koristeći standardne OLAP značajke kao što je sortirati, filtrirati, pivotirati i tako dalje. Najčešće se koristi višedimenzionalni OLAP ili MOLAP. Nažalost, baza podataka kocke ima vrlo malo kapaciteta, stane manje od 0.01% podataka nego u pravoj relacijskoj bazi. Problem ograničenosti kapaciteta kocki počeo je kada su poduzeća shvatila da im je potrebno stotine preklapanja kocke da bi pokrili sve kombinacije podatkovnih skupina.

### 3.3.3 **Ad Hoc upiti i analiza**

Ad hoc upiti su vrsta poslovne inteligencije koja omogućuje istinsku analizu poslovnih podataka, sve do razine transakcijskih detalja. Može poslužiti kao sredstvo od velikog značaja za informacijske istraživače i napredne korisnike. Najosnovniji način podrške ad hoc upita je dati korisnicima mogućnost za stvaranje potpuno novih izvješća, dopuštajući im da skupe bilo koju kombinaciju podataka u izvješću.

Neke značajke ad hoc upita su:

- Izvještavanje i vođena analiza. Korisnicima dopušta stvaranje različitih izvješća pružajući im razne parametre.
- Dubinska analiza podataka. Omogućiti korisnicima da dođu do bilo kojeg mjesta u bazi podataka pomoću OLAP funkcionalnosti.
- OLAP analiza. Dopustiti korisnicima da provedu izvješće manipulirajući preko bilo kojeg dijela baze podataka.
- Filtriranje podataka. Omogućuje korisnicima da filtriraju podatke kako bi dobili točniji skup podataka.
- Grupiranje podataka. Omogućuje korisnicima da preciziraju poslovni model ne uzrokujući nikakve promjene u bazi podataka ili cjelokupnom poslovnom modelu.

### 3.3.4 **Statistička analiza i rudarenje podataka**

Statistička analiza i rudarenje podataka namijenjeni su profesionalnim analitičarima, pojedincima koji redovito obavljaju korelacije, projekcije i tako dalje. Ovo je vrsta poslovne inteligencije koja otkriva odnose (npr. cijena) i predviđane projekcije (npr.

prodaja) pomoću postavljenih teoretskih tehnika, statističkih obrada i drugih naprednih matematičkih funkcija. Ova vrsta je puna matematičkih, financijskih i statističkih obrada podataka za potrebe analiza korelacije, analize trendova, financijske analize i projekcija. Specijalizirani alati rudarenja podataka teški su za korištenje; samo statističari s tehničkom obukom su u mogućnosti koristiti ih.

Da bi se došlo do velike količine podataka, rudarenje podataka koristi računalne tehnike iz statistike, strojnog učenja i prepoznavanja uzoraka. Rudarenje podataka se često miješa s pisanjem izvješća. Za razliku od poslovne inteligencije, aktivnosti rudarenja podataka ne uključuju tradicionalne izrade izvještaja. Rudarenje podataka se vrši putem specijaliziranih alata, koji izvode operacije rudarenja podataka na temelju analitičkog modela.

#### 3.3.4.1 Operacije rudarenja podataka

Alati rudarenja podataka omogućuju statističarima izgradnju analitičkih modela. Rezultati operacija rudarenja podataka su tablice i datoteke s učitanim podacima kojima se može pristupiti s upitom ili alatom za izvještavanje. Postoje četiri opće operacije rudarenja podataka:

1. Predviđanje i klasifikacija. Predviđanje i klasifikacija se koristi za predviđanje određenog događaja. To znači da analitičar ima konkretno pitanje koje on ili ona želi pitati. Model daje odgovor rangiranjem te se tako određuje vjerojatnost određene klase.
2. Analiza veza. Analiza veza utvrđuje odnose između zapisa u bazama podataka.
3. Segmentacija baze podataka. Segmentacija baze podataka grupira srodne zapise u segmente. Grupiranje je često prvi korak u selekciji podataka.
4. Otkrivanje odstupanja. Otkrivanje odstupanja traži zapise koji spadaju van norme i sugerira razloge anomalija.


Većina organizacija sjedi na vrhu zlatnog rudnika, gdje je zlato svi prikupljeni podaci o svojim kupcima i proizvodima koje njihov korisnik kupi. U tim podacima nalaze se svakakve informacije o potrošačkim navikama korisnika. Ne koristiti poslovnu inteligenciju u ovakvim podacima značilo bi gubljenje resursa. Sve konkurentnije

poslovno okruženje ima sve veću potrebu za rudarenjem podataka. Na primjer, natjecanje između telekomunikacijskih poduzeća stvorio je potrebu za analizu odljeva korisnika. Telekomunikacijska organizacija koja ne brine o svojim starim korisnicima i ne privlači nove, neće dugo preživjeti. Rudarenje podataka koristi razne algoritme kojima ide kroz golemu količinu podataka u svrhu otkrivanja skrivenih uzoraka u tim podacima. Razumijevanje tih uzoraka vodi do poboljšanja poslovne inteligencije.

Primjera za upotrebu rudarenja podataka ima mnogo. Jedan od primjera je ako manager u telekomunikacijskoj industriji želi saznati profil korisnika koji će zbog nameta vjerojatno raskinuti ugovor i otići kod drugog operatera. Također, telekom operateri još uvijek koriste reklame putem pošte direktno na adrese potrošača. No, pokazano je da je stopa reakcije u SAD-u na ovakvu reklamu oko 2%. Rudarenje podataka može pomoći u smanjivanju troška predviđanjem reakcije korisnika te slanje reklama samo onim skupinama ljudi za koje postoji velika vjerojatnost da će kupiti proizvod ili uslugu.

### 3.3.5 Isporuka izvještaja krajnjim korisnicima i obavještavanje o kritičnim situacijama

Isporuka izvještaja krajnjim korisnicima i obavještavanje o kritičnim situacijama omogućuje poduzećima distribuciju ogromnih brojeva izvještaja ili poruka na proaktivnoj i centraliziranoj osnovi, kao što i omogućuje korisnicima da se samostalno pretplate na isporuku izvještaja. To su proaktivne isporuke izvješća za obavještavanje o kritičnim situacijama i to na velikom broju ljudi na temelju nekog događaja koji se onda aktivira (eng. *trigger*) u bazi podataka.



*Slika 11, Vrste poslovne inteligencije*

Na slici 11 prikazano je koliko je neki alat sofisticiran te koliko ga ljudi zna rabiti. Na primjer, iz slike se vidi da su statistička analiza i rudarenje podataka veoma sofisticirani vrste poslovne inteligencije, no samo mali broj ljudi zna rukovoditi s tim. S druge strane, korporativna izvještavanja su manje sofisticirana, ali veći broj ljudi zna rukovoditi s time.

### 3.4 Problemi i izazovi poslovne inteligencije

Jedan od problema poslovne inteligencije jest taj što često ne osigurava djelotvorne informacije za ljude kojima je to potrebno. Da bi poslovna inteligencija imala utjecaj na donosiocima odluka, mora osigurati podatke širokom krugu korisnika, biti jednostavan za korištenje i razumijevanje te pomoći korisnicima da donose odluke u realnom vremenu u njihovom poslovanju. Većina rješenja poslovne inteligencije raspoređena su na ograničenu skupinu korisnika, a ne donosiocima odluke u cijeloj tvrtki. Također, problemi koji se javljaju u telekomunikacijskoj industriji su da korisnici previše čekaju na izvješće. Primjerice, kad se aktivira nova telekomunikacijska usluga, poslovnoj



inteligenciji potrebno je neko vrijeme da prikupi potrebne informacije, što znači da marketing čeka na krajnju isporuku rezultata te da rezultati kasne.

#### 3.4.1.1 Kritični izazovi za uspjeh poslovne inteligencije

Više od polovice svih projekata poslovne inteligencije ili ne završi ili se ne dostave značajke i prednosti koje su dogovorene na samom početku. Iako postoji mnogo razloga za neuspjeh, najveći je da se tvrtke prema projektima poslovne inteligencije odnose kao prema još jednom projektu IT odjela. Realnost je da poslovna inteligencija nije niti proizvod niti sustav. Ona je zapravo strategija koja se konstantno razvija, vizija i arhitektura koja kontinuirano nastoji uskladiti poslovanje i smjer organizacije sa strateškim poslovnim ciljevima. Uz poslovnu inteligenciju, poslovni uspjeh ostvaruje se brže, kroz jednostavniji pristup i djelotvornije informacije. Uspješna poslovna inteligencija donosi veću profitabilnost, a to je pravi pokazatelj poslovnog uspjeha. Da bi došle do uspjeha, tvrtke trebaju učiniti sljedeće:

- Donositi bolje odluke s većom brzinom i povjerenjem
- Pojednostaviti poslovanje
- Skratiti cikluse razvoja proizvoda
- Povećati vrijednost iz postojećih proizvodnih linija i predviđati nove mogućnosti
- Stvoriti bolji, fokusiraniji marketing, kao i bolji odnos s kupcima

Organizacije moraju razumjeti i odgovoriti na izazove kritične za uspjeh poslovne inteligencije. Projekti poslovne inteligencije ne uspijevaju zbog:

- Neuspjeha prepoznavanja projekta poslovne inteligencije kao međuodjelne poslovne inicijative te shvatiti da se kao takvi razlikuju od tipičnih samostalnih rješenja
- Nedostatka kvalificiranog i raspoloživog osoblja
- Previše oslanjanja na različite modele i alate
- Ne uvažavanje utjecaja netočnih podataka na profitabilnost poslovanja

Da bi uspjeli, projekti poslovne inteligencije moraju biti u skladu s planom te jasno definiranim ciljevima. Oni nisu ograničeni unutar jednog odjela. Njihova je svrha pružiti međuodjelnu primjenu. Također, sustav poslovne inteligencije mora biti lako ažuriran u stvarnom vremenu, kako bi se promjene u poslovnom okruženju odrazile u stvarnom vremenu.

### 3.5 Primjene poslovne inteligencije

Poslovna inteligencija opisuje uzimanje podataka u sirovom obliku, pretvarajući ih u nešto iskoristivo na čemu se temelji poslovna odluka. Ona omogućuje tvrtkama da iskoriste svoje podatke te povećaju svoju konkurentnu prednost. Postoji mnogo razloga zašto primijeniti poslovnu inteligenciju. Jedan je da je dobivanje prave informacije u prave ruke u pravom vremenu veoma važno. Drugi razlog je trenutni ekonomski kolaps. U nastojanju da prebrode ekonomsku krizu, poduzeća su usmjerena na dva glavna područja: smanjenje troškova i povećanje prihoda. U cilju povećanja prihoda, tvrtke se moraju usredotočiti na zadržavanje kupaca i stjecati nove. Također je bitno razumjeti profitabilnost kupaca. Samo 20 posto kupaca čini 80 posto dobiti. Tvrtke prvo moraju segmentirati bazu kupaca po profitabilnosti i pokušati zadržati najprofitabilnije. Zadržavanje tih kupaca pružit će najveću dobit.

Postoji mnogo primjena poslovne inteligencije. Nabrojat ćemo nekoliko njih.

#### 3.5.1 Analiza tržišta

Analiza tržišta osigurava vidljivost o tržištima jedne organizacije, integrirajući informacije od prodaje, kupca i financijskih izvora za cjelovitu sliku tržišta. Poslovna inteligencija omogućuje organizacijama povezati marketinške podatke s financijskim i prodajnim, a kupcima informacije kako bi donijeli strateške odluke da poboljša marketinšku učinkovitost.

Ključna područja analize su:

- Tržišta
- Planovi
- Segmenti

- Učinkovitost promocija
- Konkurentnost

### 3.5.2 Izvještaj za prodaju

Rukovoditelji i menadžeri trebaju razumjeti temeljne trendove koji stvaraju mogućnosti prodaje i rezultira pobjedom ili gubitkom. Ti trendovi mogu varirati ovisno o geografiji, obilježjima prodajnog predstavnika, prisutnost konkurenata i proizvoda. Poslovna inteligencija daje fleksibilnost izvještavanja za prikaz podataka o tijeku prodaje zajedno s atributima izbora, a pruža izravan pristup baviti se specifičnostima kada je to potrebno.

Ključna područja analize su:

- Rukovođenje prodajom
- Prihodi od prodaje
- Performanse prodaje

Primjena	Benefiti
Vođenje izvještavanja i analize- pruža analizu trendova	Omogućava bolje vođenje kompanije, kao i optimizaciju procesa upravljanja tržištem
Izvještavanje o prodaji proizvoda- nadgledaju se trendovi u prodaji proizvoda	Povećanje i poboljšanje prodaje
Izvještavanje performanse prodaje- donose se izvještaji i analize prodajnog učinka	Konstruktivno praćenje organizacije prodaje s mogućnosti da se ukaže na prednosti i nedostatke

*Tablica 1. Primjena poslovne inteligencije*

### 3.5.3 Financijsko izvještavanje i analiza

Poduzeća se oslanjaju na poslovnu inteligenciju da u cijelosti pruži uvid njihovih poslovnih i financijskih operacija. U svakoj organizaciji odjeli financija i računovodstva sve više se oslanjaju na poslovnu inteligenciju te tako analiziraju izvore prihoda i troškova, prikaz podataka na kojima se temelji izvještaj o novčanom toku te uspoređuje

planirane stvarne prihode i troškove. Izvana, organizacije moraju zadovoljiti javne računovodstvene zahtjeve za vladine organizacije i dioničare. Interno, financijski podaci moraju biti dostavljeni financijskim analitičarima i rukovoditeljima. Poslovna inteligencija u cijelosti podržava učinkovitu transparentnost, analizu i isporuku korporativnih podataka. Poslovna inteligencija stvara potpunu financijsku transparentnost.

Sigurnost, rasprostranjeno izvještavanje i rješenja koja izlaze van okvira omogućuju uspjeh implementacije. Kako se korporativni financijski podaci suočavaju s još većim nadzorom, bitno je da odjeli financija i računovodstva pruži detaljne informacije brzo i dostupno.

Poslovna inteligencija jedinstveno pruža učinkovitu transparentnost, analizu i isporuku korporativnih financijskih podataka.

Ključna područja analize su:

- Prihodi i rashodi
- Završni račun
- Analiza novčanog toka
- Obveze prema dobavljačima
- Planiranje i predviđanje
- Račun dobiti i gubitka
- Potraživanja

## 4 PRIMJENA U TELEKOMUNIKACIJSKOJ INDUSTRIJI

### 4.1 Uvod

Telekomunikacijska industrija bitno se proširila posljednjih deset godina. Nakon liberalizacije tržišta i privatizacije državnih monopolista tehnologija je napredovala. Glavni izazovi s kojima se suočava telekomunikacijska industrija su:

- Povećano nezadovoljstvo kupaca s postojećim telekom uslugama
- Tržišna nesigurnost i prekomjeren dug
- Ograničen tržišni kapital
- Velike, skupe i nepopustljive IT infrastrukture

Izvorni sustavi rade bez prestanka i naglasak se stavlja na kvaliteti same usluge. Dakle, ovdje nije važno da se izrade kvalitetna izvješća pa poslovna inteligencija pada u drugi plan.

U današnjem veoma izazovnom poslovnom okruženju mnogi telekomunikacijski operateri mjere svoj uspjeh veličinom i rastom svoje profitne marže. Sposobnost da se natječu u mnogo širem nizu tržišta otvorila je zatvorenu telekomunikacijsku industriju i izgledi novih sudionika na tržištu također su postali stvarnost. Novi operateri dobivaju značajne tržišne udjele.

U konkurentskim telekomunikacijskim sredinama, kupci sami biraju svog davatelja usluga. Pod konkurentskim uvjetima, kupac postaje središte pozornosti. Zahtjevi kupaca ne samo da mogu odrediti servis usluge, već mogu oblikovati mrežu i utječu na organizacijsku strukturu. Gotovo sve telekomunikacijske tvrtke danas reagiraju do kritične potrebe da se natječu učinkovitije:

- Brzo se mijenjaju, sve su konkurentniji
- Sve drugačije tržišno ponašanje
- Smanjuju vrijeme implementacije nove usluge od ideje do izlaska na tržište

### 4.2 Kupac je u središtu pozornosti

Kako na telekomunikacijskom tržištu konkurencija postaje sve jača i veća, potrebno je reagirati brzo i odlučno na tržišne trendove i prilagoditi proizvode i usluge za pojedine korisnike. Važan dio telekomunikacijskog sektora je razumjeti želje i ponašanje kupaca.

Imperativ je da se razumiju svi parametri kupca. Telekomunikacijska industrija je u jedinstvenoj poziciji da razumije kupce jer svoju energiju može usmjeriti u različite dijelove za dobivanje podataka o korisnicima. Danas telekomi znaju tko su im isplativi kupci te koje usluge ti korisnici koriste da bi bili profitabilni.

Ključ uspjeha je da se predvide potrebe kupaca na tržištu prije konkurenata.

Telekomunikacijska industrija sadrži mnogo podataka o svojim korisnicima, a poslovna inteligencija može segmentirati profitabilnije korisnike.

#### 4.3 Izazov telekomunikacijske industrije

U današnjem izuzetno izazovnom poslovnom okruženju, telekomunikacijske tvrtke su pod intenzivnim pritiskom da smanje ili eliminiraju velike prijetnje poput curenja prihoda i neučinkovite uporabe mreže. Telekomunikacijske tvrtke oslanjaju se na analize svojih velikih količina podataka te su velika skladišta podataka i rješenja poslovne inteligencije veoma bitni kako bi došli do pravog cilja.

Sve više i više informacija se nadzire, kontrolira i upravlja da bi se optimizirao poslovni proces. Skladišta podataka pohranjuju količine podataka te se ta količina povećava kao nikad prije. Mnoge telekomunikacijske funkcije oslanjaju se na brzu i kompleksnu analizu podataka. Potpora u odlučivanju obuhvaća, između ostalog, analizu ponašanja korisnika pomoću programa za upravljanje odnosima s korisnicima, kako bi se moglo optimalno usmjeriti usluge i smanjiti gubitke, osiguravajući potpunu i točnu naplatu. Učinkoviti programi poslovne inteligencije povećat će profitabilnost, dok će s druge strane uklanjati prepreke i analizirati dinamične detaljne informacije.

Tehnologija poslovne inteligencije omogućuje organizacijama da transformira podatke pohranjene u osnovne poslovne sustave što omogućuje da upoznaju svoje korisnike te da bi korisnici znali za njih i pojednostavljenje poslovnih procesa, usklađujući tehnologiju s poslovnim ciljevima.

Visoka učinkovitost alata za poslovnu inteligenciju kao što je napredna analitika i izvješća igraju važnu ulogu u telekomunikacijskoj industriji danas. Vrijednost poduzeća leži u agresivnom zadržavanju i rastu baze korisnika.

Odjeli koji primaju najveću korist od poslovne inteligencije su:

- Marketing: nadgledavanje marketinških proizvoda
- Služba za korisničku podršku: zadržavanje korisnika i njihovo zadovoljstvo
- Mrežne operacije: zadržavanje i poboljšavanje mreža i usluga
- Financije: praćenje troškova i marketinške potrošnje

#### 4.4 Skladištenje podataka u telekomunikacijskoj industriji

U svakodnevnom poslovanju sve poslovne aktivnosti bilježe se na transakcijskim sustavima. Transakcijski sustav je relacijski model, te sadrži veliku količinu podataka. Relacijski model je pak složen model podataka, nerijetko ima na tisuće entiteta, te je teško razumljiv krajnjem korisniku. Također, nema grafičkog sučelja kojim bi se mogao pregledavati općeniti relacijski model podataka. Upiti su komplicirani i sporo se odvijaju, a to predstavlja problem pri pronalaženju optimalnog rješenja. Ideja je bila predstaviti korisnicima podatke kroz jednostavniji i lakše razumljiv model.

Skladište podataka prikuplja i objedinjuje podatke te ih pripremi za upite koji će poslužiti kao potpora poslovnom odlučivanju. Tako su pri analizi rasterećeni transakcijski sustavi jer se svi upiti postavljaju nad skladištem podataka. Također, ubrzava se izvještavanje, omogućuje se analiza aktualnih podataka, podaci su preoblikovani u oblik koji je korisnicima jednostavniji i pristupačniji.


Usporedba transakcijskog sustava i skladišta podataka dana je tablicom.

TRANSAKCIJSKI SUSTAV	SKLADIŠTE PODATAKA
Sadrži trenutne podatke	Sadrži povijesne podatke
Sadrži detaljne podatke	Sadrži detaljne i sumarne podatke
Vrijeme odziva je nekoliko sekundi	Vrijeme odziva od nekoliko sekundi do nekoliko sati
Normalizirani podaci	Denormalizirani ili djelomično denormalizirani podaci
Velika učestalost transakcija	Srednja i mala učestalost transakcija
Predefinirani upiti	Analitički upiti
Težište na pohranjivanju podataka	Težište na dobavljanju informacija

*Tablica 2. Usporedba transakcijskog sustava i skladišta podataka*

Skladište podataka je:


- subjektivno orijentiran, to jest u skladištu podataka podaci su organizirani oko korisnika, a nepotrebni podaci su izostavljeni..



*Slika 12, Integracija skladišta podataka*



- Integriran. Podaci su prikupljeni iz više različitih izvora, tako da u različitim sustavima određeni atribut je različito nazvan. Primjerice, ako je korisnik aktivan ili deaktiviran, u jednom sustavu može biti označeno s A i D, u drugom s 0 i 1, a u trećem s ACTIVE i DEACTIVE. Skladište podataka skupi sve podatke te ih normalizira. Na slici 12 pokazana je integracija skladišta podataka.



*Slika 13, postojanost skladišta podataka*

- Postojan. Podaci u skladištu podataka su postojani. Za razliku od transakcijskog sustava gdje se može učitati, izbrisati, ubaciti ili ažurirati, skladište podataka namijenjeno je samo za učitavanje, te je to prikazano na slici 13.
- Vremenski uvjetovan. Podaci koji dopiju u skladište podataka u pravilu se ne mijenjaju, no svaki podatak sa sobom nosi vremensku oznaku što znači da je svaki podatak točan ali samo u određenom trenutku na koji se odnosi

U telekomunikacijskoj industriji postoji čitav niz poslovnih procesa koji se mogu predočiti dimenzijskim modelima podataka za skladište podataka. Svaki poslovni proces pokriva određenu granu poslovanja telekomunikacijskog operatera. Dok je nekad za implementaciju bilo prihvatljivo čekati mjesecima, danas je prihvatljivo nekoliko tjedana. Krajnji korisnici žele nove usluge uz manje cijene. Nameću se novi nameti na

ostvarenu dobit. Sve su ovo izazovi s kojima se susreće telekomunikacijska industrija, a pravi put do ostvarivanja svog cilja je uvođenje skladišta podataka. Skladište podataka sadrži podatke iz svih relevantnih transakcijskih sustava.

#### 4.4.1 Informacije o korisnicima

Telekomunikacijska industrija, kako je već spomenuto, na tržištu poslovne inteligencije ima prednost pred drugim industrijama zbog količine podataka koje već posjeduje o svojim korisnicima. Važnost dobrog dimenzijskog modela za osnovne korisničke podatke je nemjerljiva. Kada se govori o potrošnji korisnika, njihovoj vrijednosti, troškovima, interakcijama sa službom za korisnike i svim drugim aspektima korisničkog života, bitno je dobro znati o kojem se korisniku radi. Osnovna stvar u telekomunikacijama je ugovor. S obzirom da je industrija napredovala, poznajemo 3 situacije:

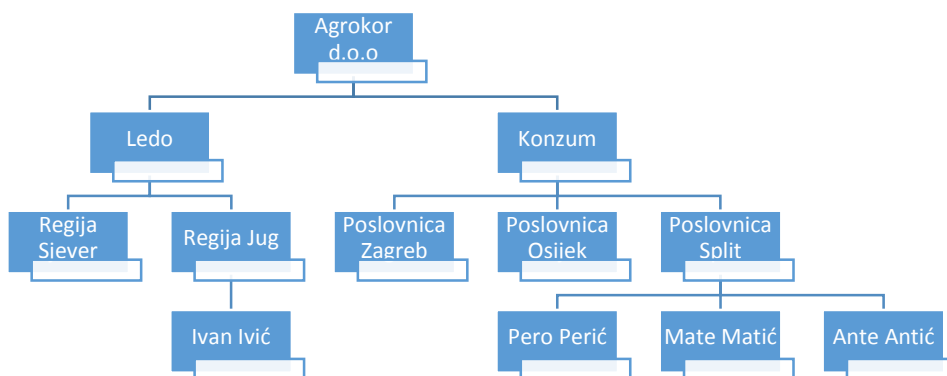
- Pretplatnički ugovor s ugovornom obvezom
- Pretplatnički ugovor bez ugovorne obveze
- Ugovor na bonove

Ugovor je poslovni odnos između korisnika i operatera. Operater dostavlja korisniku račun za pružene usluge koje su navedene u ugovoru. Sam ugovor mora sadržavati tarifni model unutar kojeg su obuhvaćene sve usluge koje je korisnik zatražio. Svaki ugovor ima definiranu platežno odgovornu (eng. *payment responsible*) osobu. To ne mora biti korisnik kojem pripada korisnik. Na primjer, poduzeće se obvezuje plaćati do nekog fiksnog iznosa, dok sve iznad tog iznosa plaća sam korisnik. Ovakav način plaćanja naziva se odvojeni način plaćanja (eng. *split billing*).

Kod pretplatničkih ugovora korisnik svoju potrošnju i tarifu plaća jednom mjesečno. Za svaki poziv koji radi ili poruku koju šalje, račun se ispostavlja tek na kraju obračunskog razdoblja. Za razliku od pretplatničkih ugovora, ugovor na bonove funkcionira tako da se odmah po završetku korištenja telekomunikacijske usluge korisniku naplati njegova potrošnja. Samim time, korisnik mora osigurati da prije ostvarivanja poziva ili slanja poruke ima dovoljan iznos novaca na računu.

Nakon što smo definirali ugovor, prelazimo na samog korisnika. U ideji, ova veza se može opisati kako jedan ugovor ima točno jednog korisnika i obratno. U stvarnosti, situacija je drugačija. Poslovni subjekti nerijetko trebaju na istom računu dobiti sve ugovore koji pripadaju tom poduzeću. Samim time, pod jednim korisnikom pripada, ako je potrebno, više od jednog ugovora. Uz to, velike korporacije mogu imati vezu prema više instanci svojeg poslovanja. Primjerice, jedna korporacija ima oznaku svoje kompanije, ali pojedine račune plaćaju njeni ogranci ovisno o geografskoj pripadnosti. Ako tvrtka na razini Hrvatske ima 10 poslovnica, svaka poslovnica barata svojim troškovima, pa samim time i plaća svoje račune. Prepoznate su 3 glavne razine kod svakog ugovora:

- Korisnik koji koristi uslugu (svaka osoba ima svoj ugovor)
- Korisnik koji plaća za navedenu uslugu (za svaku osobu koja plaća račun možemo imati više ugovora)
- Korisnik koji predstavlja poduzeće (za svaku osobu koja predstavlja poduzeće imamo više osoba koje plaćaju za svoje usluge). Na slici 14 prikazana je hijerarhija poduzeća Agrokor.



*Slika 14, hijerarhija poduzeća*

Svaki ugovor u ovoj priči ima svoje entitete. Jedan od najvažnijih entiteta je tarifa korisnika. Ona predstavlja osnovni proizvod svakog telekoma. Svaka tarifa predstavlja neki segment korisnika kojem je namijenjena, nosi mjesečnu naknadu, te definira cijenu pojedine jedinice poziva ili poruke, i određuje što sve korisnik plaća unutar mjesečne naknade.

Izvorni sustavi za ovakav set informacija su najčešće sustavi za naplatu korisnicima te upravljanje odnosima s korisnicima. Struktura podataka ne omogućava jednostavan pregled navedenih entiteta jer zbog kompleksnosti stvarnog svijeta i količine podataka koju neki sustav treba sadržavati, izvorni sustavi sadržavaju samo trenutne informacije o korisnicima. U posebnim relacijskim tablicama možemo pronaći i promjene statusa ugovora te na odvojenim mjestima produljenja pretplatničkih ugovora. Također, bitno je spomenuti kako na naplatnom sustavu postoje velike razlike u odnošenju prema pretplatničkim ugovorima i ugovorima na bonove. Različiti načini naplate često iz povijesnih razloga povlače dva potpuno različita sustava koji se brinu o tim korisnicima. U moderno doba često se spominju pojmovi poput konvergentnog naplatnog sustava. Takav sustav rješava probleme različitih načina naplate korisnicima ali je često skup za implementaciju i u početnim fazama razvoja telekomunikacijske kompanije nije isplativ.

U skladištu podataka korisnik i njegov ugovor trebaju postojati u istim strukturama neovisno o pripadnosti izvornim sustavima. Također, različiti događaji u životima korisnika trebamo svesti na isti nazivnik. Svaki od spomenutih entiteta, ugovor, korisnik, tarifa, može na sebi nositi nebrojeno mnogo drugih informacija važnih za izvještavanje. Sve te informacije mogu doći s bilo kojeg sustava koji ima poveznicu na neki od izvornih sustava koje smo već uzeli u obzir. U skladištu podataka često ostavljamo vezu prema izvornim sustavima u vidu prirodnih ključeva dimenzija, ili broja transakcije ako govorimo o činjeničnim zapisima.

#### 4.4.2 Izazovi i nedostaci skladištenja podataka

Skladište podataka može sadržavati podatke iz raznih izvornih sustava. Podatak će biti izvađen, pretvoren te se učitava u skladište. Poslovni korisnici tada mogu zatražiti posebna ad hoc izvješća. Iako je vrijednost analize podataka neupitna, postoje tri glavna nedostatka u pristupu skladištenja podataka.

1. Troškovi i složenost uspostave skladišta podataka su veliki. Implementacija i upravljanje troškovima dosežu milijunske iznose. Takvo okruženje zahtijeva osobe koje se mogu tome posvetiti.

2 . Postoji potreba za dohvaćanjem, transformiranjem i učitavanjem podataka u skladište podataka. Tom procesu treba vremena, tako da korisnici neće primiti najsvježije podatke.

3 . Alati za analizu podataka koji borave u skladištu podataka su dizajnirani za analitičare. Nisu prikladni za krajnje korisnike, menadžere ili rukovoditelje, tako da ti pojedinci moraju zatražiti usluge analitičara za stjecanje izvješća koje im je potrebno. To uzrokuje kašnjenja te korisnik ne može primiti najsvježije operativne dostupne podatke. Sve većem broju organizacija je potrebno dohvatiti podatke u stvarnom vremenu kako bi donijeli pravu odluku i ostali konkurentni. Arhitektura skladišta podataka nije prikladna za organizacije ili menadžere koji odmah trebaju operativne podatke u stvarnom vremenu. Čekanje po nekoliko dana ili tjedana nije održivo. Većina poduzeća dobila bi konkurentnu prednost kad bi se smanjilo vrijeme provedeno za prikupljanje podataka. U tim slučajevima, poduzeća često implementiraju poslovnu inteligenciju, no to nosi značajne operativne troškove.

Skladištenje podataka nije nova pojava. Sve velike organizacije imaju skladište podataka. Porastom novih proizvoda i tehnologija tijekom sljedećih nekoliko godina, rast skladištenja podataka će biti enorman. Skladištenje podataka brzo se razvio u jedinstven i popularan posao. Sve više i više poduzeća koriste skladište podataka kao strateški alat da im pomogne osvojiti nove kupce, razvoj novih proizvoda, te smanjiti troškove.

Pretraživanje po velikom broju podataka koje generiraju korporativni transakcijski sustavi mogu pružiti uvid i istaknuti kritične činjenice koje mogu značajno poboljšati poslovanje. Donedavno, skladištenje podataka bilo je rezervirano uglavnom za velika poduzeća, ali smanjeni troškovi tehnologije skladištenja čine ga praktičnim i za mala poduzeća.

#### 4.5 Poslovna inteligencija u telekomunikacijskoj industriji

Telekom je među prvim industrijskim granama koji je doživio prednost poslovne inteligencije. Također, telekom je prvi počeo eksperimentirati s načinom rada poslovne inteligencije. Među prvim zahtjevima koje je poslovna inteligencija dobila bilo je smanjenje gubitka kupaca. Korištenje poslovne inteligencije, povezanim sa sustavom za

upravljanje odnosa s korisnicima, pomoglo je identificirati korisnike koji su se prebacili na drugog davatelja usluga, analizirajući broj pritužbi registriranih korisnika.

Danas telekomunikacijske tvrtke mogu dati osnovne odgovore veoma brzo. Međutim, složena pitanja trebaju se odgovoriti što prije. Na primjer, danas znamo tko su nam korisnici i što marketinški učiniti za njih. Međutim, ako želimo znati koji kupci su profitabilni, koje usluge korisnici koriste da budu profitabilni te koje marketinške kampanje trebaju biti usmjerene na tom segmentu, takvi podaci se trebaju izvući iz više sustava i potrebno je manipulirati složenim proračunskim tablicama. Isto vrijedi za mnoge druge procese djelovanja.

Većina operatera ima razne sustave za upravljanjem aktivacijom kupca, jer aktiviranje novih kupaca vodi do novih prihoda te je važno napraviti aktivaciju u što kraćem vremenu. Primjena poslovne inteligencije spaja nepovezane sustave i podatke iz različitih izvora te omogućuje poslovnom korisniku da donese pravu odluku. Alati za izvještavanje se koriste za upite na bazu podataka te osiguravaju redovita izvješća poslovnih korisnika. Rješenja su jednostavna za korištenje tako da korisnik također može kreirati vlastite izvještaje i napraviti ad hoc upite ako je potrebno. Analitičke i digitalne aplikacije mogu ići korak naprijed te dodijeliti korisniku prava tako da može djelomično upravljati podacima. Na temelju toga korisnik može, na primjer, postaviti upozorenja zbog unaprijed određenih poslovnih pravilima. No, nisu sve usluge atraktivne za sve kupce, a vrlo je skupo pokretanje marketinške kampanje te je zbog toga još važnije upoznati svog korisnika te predvidjeti koje usluge bi mu se svidjele a koje ne bi. Potrebno je razumjeti utjecaj marketinške kampanje prije i biti u mogućnosti poduzeti korektivne mjere ako bi bilo potrebno. Bez primjene poslovne inteligencije, rezultati marketinške kampanje ne bi se znali tri do četiri mjeseca. S alatom poslovne inteligencije, može se doći do aktivacija kupaca na dnevnoj bazi bez da se mora čekati mjesecima. To omogućuje brzu prilagodbu ako kojim slučajem proizvod ne ispuni svoje ciljeve.

#### 4.5.1 Inteligentno vođenje korisnika

Od desetaka tisuća korisnika u organizacijama, tisuću korisnika pruža 80% prihoda. Poduzeće treba vidjeti aktivnosti korisnika, interakcije sa korisnikom usluga, obveze prema dobavljačima, prodaju i marketing.

U današnjem konkurentskom okruženju, prirodni odnos s korisnikom se promijenio. Potrošači imaju puno više izbora kako bi zadovoljili svoje potrebe te se agresivno oglašavanje i pristup internetu sve više proširuje. Tvrtke se natječu za istog korisnika, a uspješne tvrtke moraju osigurati vrhunski odnos s korisnicima kako bi se istaknuli.

#### 4.5.2 Upravljanje odnosima s korisnicima

Upravljanje odnosima s korisnicima (eng. *Customer Relationship Management*, CRM) nastao je iz potrebe za povećanjem profita. Definicija CRM-a bila bi strategija prikupljanja važnih podataka o korisnicima i korištenje tih podataka u svrhu dugoročne profitabilnosti. CRM podrazumijeva sve aspekte interakcije organizacije sa korisnicima, bez obzira na to radi li se o prodaji ili uslugama. Ukratko, to je efikasno upravljanje odnosa organizacije i njenih korisnika. CRM je nastao u ekonomijama zapadnog svijeta u organizacijama kojima je postao prioritet zadržati postojeću bazu korisnika uslijed jakog prodiranja proizvoda ili usluga na tržištu te snažne konkurencije. Pojam CRM danas vrlo često podrazumijeva tehnologiju koja jednako upravlja odnosima s korisnikom, a obuhvaća rješenja za upravljanje marketingom, prodajom i pružanjem usluge korisniku.

Za razvoj CRM-a postoji mnogo razloga. Neki od njih su:

1. Troškovi privlačenja novih korisnika su i do pet puta veći u odnosu na troškove njihovog zadržavanja.
2. Mnogi korisnici su neprofitabilni, te je uočeno da 20 posto korisnika ima kapacitet za ostvarenje 80 posto dobiti.
3. Organizaciju zanima pojedinačna profitabilnost svojih korisnika
4. Sustav za upravljanje korisnicima mora prikazivati stvarne podatke i informacije korisnika u realnom vremenu

#### 4.5.3 Događaji u životu korisnika

Svaki korisnik prolazi kroz nekoliko faza u svom životnom ciklusu u svijetu telekomunikacijskih usluga. Svim tim događajima dolazimo do kreiranja možda i najvažnijeg izvještaja, a to je pregled broja korisnika. Kako je već nekoliko puta spomenuto, izvorni sustavi moraju raditi u svakom trenutku i omogućiti krajnjim korisnicima korištenje telekomunikacijskih usluga. U takvom svijetlu, logično je da dolazimo do izazova u ispravnom praćenju broja korisnika ako znamo da fokus nije na ispravnom izvještajnom sloju, već je fokus na kvaliteti usluge. Niti jedan sustav nije savršen, i svi naknadni ispravci utječu na izvještavanje.

Važni događaji u životu korisnika:

- Grossadd – aktivacija novog korisnika i njegov inicijalni dolazak u kompaniju
- Suspenzija – ukoliko korisnik ne plaća račune na vrijeme ili odluči zaustaviti korištenje svoje usluge zbog odlaska u inozemstvo na neko vrijeme, korisnikov ugovor može biti zamrznut. U ovom stadiju korisnik ne može koristiti usluge, ali mu se ništa niti ne naplaćuje
- Reaktivacija – povratak korisnika i ponovno omogućavanje korištenja usluge
- Promjena tarife – korisnik može u svakom trenutku odlučiti promijeniti tarifu i takve promjene moraju biti zapamćene u skladištu kako bi ispravno u svakom trenutku znali odrediti koliko smo imali korisnika na kojoj tarifi. Izvorni sustavi sadrže informaciju samo o trenutnoj tarifi korisnika, dok svaku promjenu najčešće lovimo nekim od mehanizama praćenja promjena na izvornim sustavima (sinkronizacija podataka, CDC – bilježimo sve promjene na izvornim sustavima, itd.)
- Migracija korisnika – promjena između ugovora na bonove i pretplatničkih ugovora promatra se kao migracija korisnika između dvije vrste plaćanja
- Produljenje ugovorne obaveze – kod korisnika s pretplatničkim ugovorom bitno je znati koliko je korisniku preostalo do isteka ugovora, kako bi pravovremeno korisniku mogli ponuditi novu uslugu



- Aktiviranje dodatnih usluga – svaki korisnik može kupiti dodatan paket usluga poput neograničenih poziva prema drugim mrežama, opciju s kojom više ne plaća uspostavu poziva, određenu količinu poziva u inozemstvu...
- Churn – deaktivacija korisnika i njegov odlazak iz kompanije

Svaki od ovih događaja predstavlja važan trenutak u korisničkom životu. Prvi korak je saznati koliko je korisnika na određeni dan došlo na neku tarifu ili otišlo sa neke tarife. Nakon što to saznamo iz aspekta svih ovih događaja postavlja se iduće pitanje. Koja prodajna mjesta su isplativa, odnosno, radi li neko prodajno mjesto negativan učinak na naš broj korisnika? Tvrtke često nemaju samo svoje dućane već sklope ugovore s franšizama i partnerima koji time postaju zastupnici za prodaju njihovih usluga. Njih se plaća po obavljenom učinku. Na svaki od ovih događaja trebamo dovesti informaciju o prodajnom mjestu i osobi koja je odradila taj događaj. U svakom trenutku, neovisno o situaciji na izvorišnim sustavima, ova informacija treba biti pravilno propagirana do skladišta podataka.

#### 4.5.4 **Primjene poslovne inteligencije u telekomunikacijskoj industriji**

**Upravljanje prijevarama**(eng. *Fraud Management*). Alat za otkrivanje prijevara pomaže zaustaviti razne prijevare i radi veoma učinkovito. Koristi povijesne podatke pri izgradnji modela lažnih ponašanja i rudarenje podataka da identificira slične slučajeve. Veoma se lako može otkriti moguća lažna aktivnost, kao i operativni problemi koji se mogu riješiti. Upravljanje prijevarama uključuje analizu prijevara, korektivne mjere i notifikacije, cjenovne modele, trajanje poziva, vrijeme poziva, vrijeme odziva te produktivnost zaposlenika. Primjer korištenja ovog alata je kada korisnik neuspješno pokušava iskoristiti već iskorišteni bon velik broj puta zbog pokušaja prijevare.

**Financijska analiza**(eng. *Financial Analysis*). Ovaj alat poslovne inteligencije omogućuje telekomu uzeti financijsku analizu kad god je to potrebno. Ispitivanje financijskih rezultata cijelog poduzeća može voditi do najprofitabilnije moguće poslovne odluke. Područja koja su uključena su izvještavanje prihoda, analiza troškova, tarife, porezi, ugovorna izvještavanja i analiza proračunske varijance.

**Marketinška analiza**(eng. *Marketing Analysis*). Zbog ovog analitičkog alata kategorija upravljanja telekomunikacijskih usluga je učinkovitija zbog analitike planiranje, cijene, operacija, promjenjivih mreža. Obuhvaća up-sell analizu, down- sell analizu, cross-sell analizu, programe vjernosti, segmentaciju kupca, demografsku analizu, povijest usluga i tržišni udio.

**Optimiziranje mreže**(eng. *Network Optimization*).Održavanje profitne marže zahtijeva optimalnu učinkovitost mreže. Analitički alati stvaraju izvješća u stvarnom vremenu. Upozorenja se isto mogu kreirati za trenutne obavijesti i krizne situacije koje zahtijevaju brz odgovor. Ovo obuhvaća prometnu analizu, mrežno planiranje, kvalitetu usluge, korištenje mreže, usmjeravanje poziva i analizu kapaciteta

**Analiza prodaje i naplate**(eng. *Sales Analysis and Billing*). Snažan alat za dobivanje uvida iz terabajta podataka povezane s prodajom i naplatom za rezidencijalne, poslovne, bundled servise. Iskoristiva analiza podataka daje konkurentnu prednost otkrivajući profitabilnije prodajne prilike. Analiza obuhvaća prihode od prodaje i trendova, trendove kupaca, izvještaje o provizijama, stanje računa, analizu prijevara, prodaju i reklamiranje preko telefona.

**Služba za korisnike i analitički CRM**(eng. *Customer Care and Analytical CRM*). Žestoka konkurencija za korisnike diljem telekomunikacijske industrije zahtijeva veće napore brige oko kupaca. Ova primjena poslovne inteligencije omogućuje telekomima da segmentiraju korisnike demografski, po naplati i ostalim kriterijima te omogućujući tako menadžerima razvoj učinkovite strategije koje će osvojiti i zadržati profitabilne korisnike. Ova analiza uključuje analizu odljeva korisnika, plan migracije korisnika, usluge pritužbe, usluga pozive i nadgledavanja, postavke i dozvole.

**Tarifni kalkulator**. Prodajni predstavnici na raspolaganju imaju sve podatke o korisnicima i uslugama koje telekom nudi svojim klijentima. Od svih tih silnih informacija, u relativno kratkom vremenu, potrebno je pokazati konkretne opcije koje se korisniku isplati nuditi, odnosno koje su za njega profitabilne. S obzirom na kompleksnost samih ponuda, ovaj alat mora analizirati „što ako?“ situacije, u kojima se korisnikova potrošnja naplaćuje prema različitim tarifama i opcijama kako bi znali što je

to što korisniku treba. Ovaj primjer je ujedno i implementiran te detaljnije objašnjen u nastavku rada.

## 5 TARIFNI KALKULATOR

### 5.1 Potreba za tarifnim kalkulatorom

U svakom trenutku, jedan telekom operater ima u svom portfelju razne tarife i dodatne opcije koje u određenim situacijama može ponuditi korisniku. Usluge se mogu prikazati matričnim prikazom između tarifa i dodatnih opcija. Sam pogled na jedan takav prikaz, za samo trenutno aktivne usluge, izgleda prilično kompleksno, jer u svakom trenutku u ponudi stoji preko 15 tarifa i desetak dodatnih opcija koje nude razne kombinacije dodatnih minuta ili SMS poruka za određenu cijenu.

	Opcija 1GB	Opcija CSF	MultiSIM	Opcija druge mreže	Putne minute 100
Tarifa 1	X	X	X	X	X
Tarifa 2			X		X
Tarifa 3	X				X

*Tablica 3 ponuda tarifa i raznih opcija*

U tablici 3 prikazane su tri tarife sa raznim opcijama. Opcija 1GB ima uključen 1GB data prometa pri punoj brzini, Opcija CSF prikazuje opciju bez uspostave pozive, to jest korisnik ove opcije ne plaća naknadu za uspostavu poziva. MultiSIM je jedna ili dvije dodatne SIM kartice na istom broju. Ako korisnik ima uključenu Opciju druge mreže, tada on razgovara prema drugim mrežama za 0 kuna. Zadnja opcija je Putne minute 100, gdje korisnik koji ju aktivira ima 100 minuta razgovora u inozemstvu.

Krajnji korisnici dosta često nisu svjesni svih mogućnosti i po pomoć ili informacije dolaze do prodajnih predstavnika. Postoje dvije generalne razlike kod kreiranja ponuda za korisnike. Ukoliko je korisnik na drugoj mreži i o njemu nemamo nikakvih informacija, ponudu radimo prema njegovim željama i informacijama koje korisnik podijeli s nama. Dosta velika odgovornost leži na samom korisniku kako bi nam dao što bolji uvid u svoje potrebe. Ako je korisnik već na našoj mreži, onda sve potrebne informacije već imamo. Takva situacija nam je puno povoljnija, i ovdje razlikujemo nekoliko poslovnih potreba:

- Privatni korisnik koji dolazi kod prodajnog predstavnika ili kontaktira službu za korisnike kako bi smanjio svoj račun i/ili produljio ugovor
- Poslovni korisnik koji želi za sve svoje linije produljiti ugovor
  - Ako je korisnik obveznik javne nabave onda moramo napraviti ponudu koja će biti javna
  - Ako korisnik nije obveznik javne nabave onda ponudu šaljemo direktno korisniku

U svakoj od ovih situacija, korisnik očekuje od osobe s kojom komunicira da ima za njega spremnu ponudu koja osigurava njegove potrebe. S obzirom na gore spomenutu kompleksnost, kako prodajni predstavnik u kratkom roku može doći do optimalne ponude za korisnika?

## 5.2 Tarifni kalkulator i poslovna inteligencija

Kako bi što bolje i točnije opisali korisnika i njegove potrebe, trebaju nam sve informacije o korisnikovim trenutno aktivnim uslugama, ali što je još važnije, potrebni su nam njegovi povjesni podaci. Trenutni status u svakom slučaju najbolje oslikava sustav za upravljanje korisnicima koji je već prisutan na prodajnom mjestu. Podaci koji se tamo nalaze su zapravo „živi“ podaci na transakcijskom sustavu i većinom se radi o trenutno aktivnim dodatnim uslugama, tarifi, imenu i prezimenu klijenta, identifikacijskim oznakama, statusom i slično. Te nam informacije niti približno nisu dovoljne za odrediti idealnu ponudu. S druge strane, pretpostavimo da telekom ima milijun klijenata. Svaki od tih klijenata u prosjeku dnevno odradi 5 poziva, pošalje 5 SMS poruka i spoji se 5 puta na Internet. Samo na osnovu tih informacija možemo zaključiti da u mjesec dana raspolažemo s 450 milijuna zapisa. Ovo je samo gruba aproksimacija, ali dovoljna da zaključimo kako nekakvu preciznu analitiku nad takvim podacima ne možemo imati. Za pravilno korištenje tarifnog kalkulatora trebamo imati standardne i već unaprijed definirane dimenzije koje opisuju što korisnik ima, cijene po uslugama i tarifama koje imamo (ili smo imali) u portfelju te najvažnije, posebno pripremljenu korisničku potrošnju. Zadnje je glavna činjenična tablica oko koje se promatra cijeli ovaj proces, odnosno, to je glavno područno skladište kojim raspolažemo. S obzirom da ovdje

krećemo od finalnog oblika činjenične tablice koji prvo trebamo definirati, možemo reći kako je jedina ispravna metodologija za implementaciju tarifnog kalkulatora pristup od dna prema gore, odnosno metodologija koju propisuje Ralph Kimball. Ovdje možemo imati problema jedino kod usklađivanja brojki dobivenih kroz tarifni kalkulator sa službenim izvještajima tvrtke ukoliko se unaprijed ne konsolidiraju te dvije potpuno različite perspektive.

### 5.3 Izvedba tarifnog kalkulatora

Za svakog korisnika moramo imati spremnu njegovu potrošnju za proteklo razdoblje. Potrošnja mora biti svedena na granulaciju koja nama odgovara. Na primjer, uzeti su u obzir podaci o mjesecu potrošnje, korisniku te tipu potrošnje korisnika. Prve dvije dimenzije su već objašnjene, dok treću još nismo susreli. Tip korisničke potrošnje za potrebe ovog primjera razložili smo na:

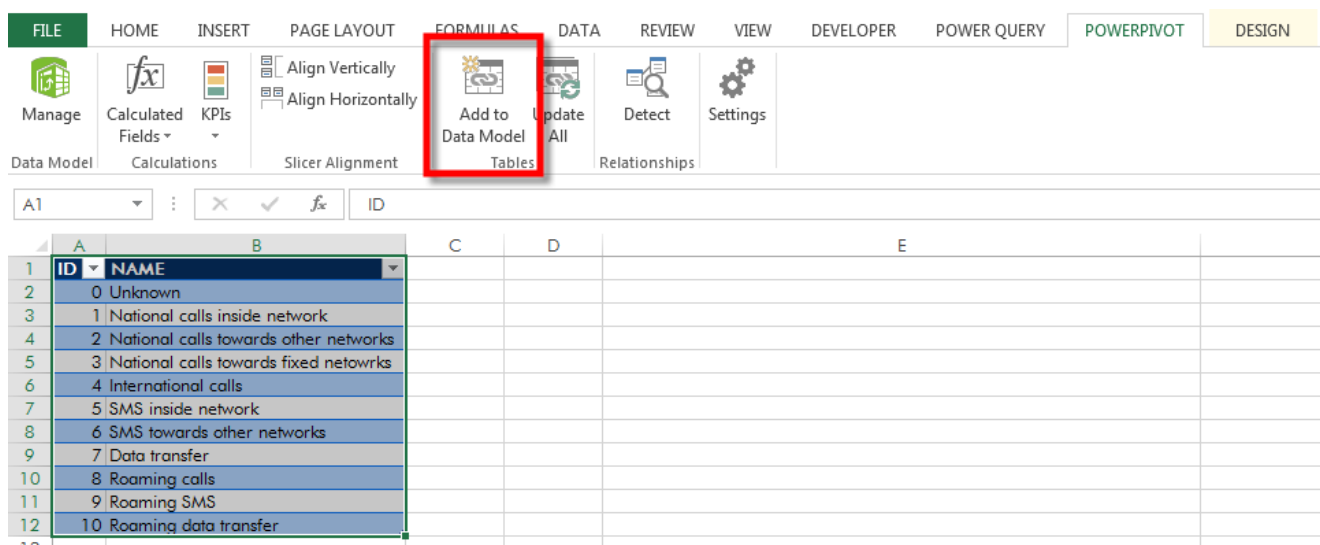
- National calls inside network – pozivi unutar mreže
- National calls towards other networks – pozivi prema drugim nacionalnim mobilnim mrežama
- National calls towards fixed networks – pozivi prema fiksnim mrežama
- International calls – pozivi prema internacionalnim destinacijama
- SMS inside network – SMS poruke unutar mreže
- SMS towards other networks – SMS poruke prema drugim nacionalnim mobilnim mrežama
- Data transfer – prijenos podataka unutar Hrvatske (odnosi se i na download i na upload)
- Roaming calls – pozivi u inozemstvu, dolazni i odlazni
- Roaming SMS – SMS poruke u inozemstvu
- Roaming data transfer – prijenos podataka u inozemstvu

Jedna dimenzija u pravilu nije dovoljna kada definiramo potrošnju korisnika. Svaka sljedeća ponuda može biti detaljnija. Recimo da se na tržištu pojavi nova tarifa, nazovimo je „Tarifa X“. Ona u sebi sadrži 50 minuta poziva unutar samo jedne države u inozemstvu. U tom trenutku, naš tip poziva „Roaming calls“ potrebno je promijeniti na

neki način, ili je pregled potrošnje korisnika i definiranje nove potencijalne tarife potpuno beskoristan. Iz tog je razloga dosta bitno da sektor marketinga i prodaje zajedno sa tehničkim sektorom definiraju razinu detalja koja je potrebna, na osnovu informacija kojima trenutno raspolažu.

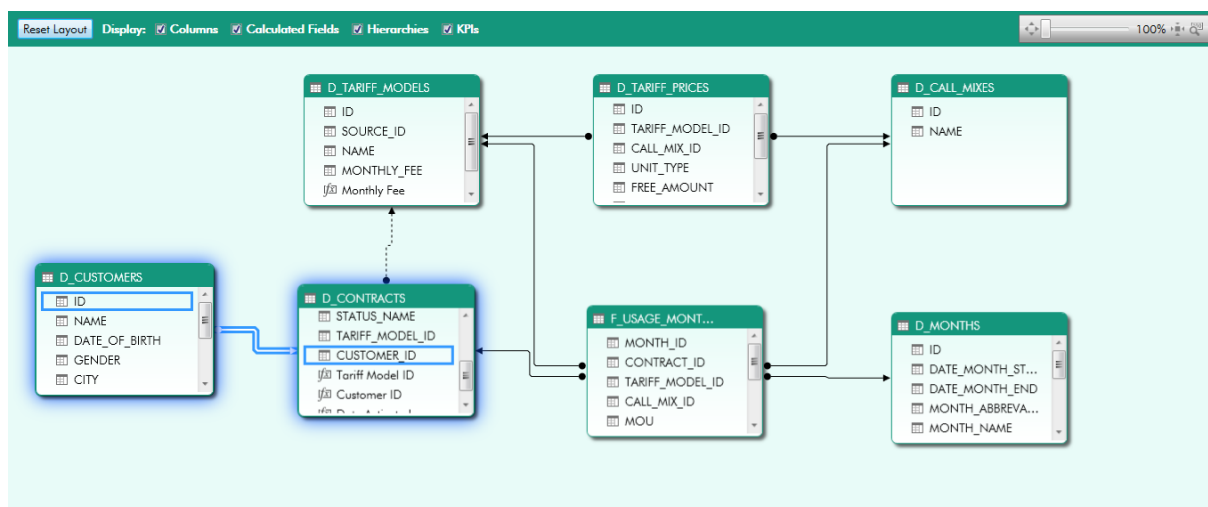
Uz navedenu dimenziju, potrebna nam je i jedna dimenzija koja definira cijenu pojedinog tipa potrošnje na svakoj tarifi. Radi se zapravo o kartezijevom produktu između tarifa i tipa potrošnje, kod koje smo dodali iznos koji je uključen u samu mjesečnu naknadu, te cijenu jedinice potrošnje nakon što korisnik potroši sve što je već uključeno u tarifu. Kao što se može vidjeti, dodatne usluge su ovaj puta zanemarene.

Nakon što smo definirali sve potrebne entitete kojima trebamo raspolagati, krećemo u izgradnju rješenja. Kao tehnologiju, odabrala sam alat „Microsoft Excel“ i najnoviji set podataka pod nazivom „Power BI“. Microsoft je krenuo u smjeru „Self-service BI“ rješenja, odnosno alate koje bi sami krajnji korisnici koristili u svrhu dolaženja do potrebnih informacija, bez skupih rješenja koja nisu modularna. U sklopu ovog paketa, glavni dodatak se skriva pod nazivom „Powerpivot“. Po prvi puta omogućena je manipulacija semantičkim modelom podataka u sklopu samog Excela. Kao izvori podataka, kako bi rješenje bilo prenosivo i bez spajanja na bazu (komplikacije sa propuštanjima i dostupnosti poslužitelja, brzina veze i slično), podaci su iz same baze podataka prebačeni u Excel. Svaki sheet predstavlja jednu tablicu te su tako i nazvani. Svaka pojedina dimenzija ili činjenica se u semantički model dovodi na jednostavan način. Označimo tablicu u Excelu i označimo opciju „Add to model“.



Slika 15

U sklopu semantičkog modela, definirali smo sljedeće dimenzije i činjenične tablice te njihove veze, odnosno referencijski integritet.



Slika 16, zvjezdasti dimenzijski model



Nakon što imamo kompletno definirani semantički model, moramo definirati mjere koje ćemo kasnije koristiti u sklopu našeg rješenja. Za potrebe tarifnog kalkulatora definirali smo i neke nestandardne mjere poput surogatnih stranih ključeva iz dimenzijskih tablica. Razloge za ovakvo rješenje ćemo detaljnije objasniti kasnije. Svaka mjera se definira u sklopu dimenzije ili činjenice iz koje uzimamo podatke. S obzirom na potrebe koje smo imali, gotovo svaka mjera ima jednaki format:

ID	TARIFF_MODE...	UNIT_TYPE	FREE_AMOUNT	REGULAR_PRICE	CALL_MI...	Add Column
1	Mou		0	0	1	
2	Mou		0	0	2	
3	Mou		0	0	3	
4	Mou		0	2	4	
5	Units		0	0	5	
6	Units		0	0	6	
7	Data		1024	1	7	
8	Mou		0	3	8	
9	Units		0	2	9	
10	Data		0	7	10	
11	4 Mou		0	0	1	
12	4 Mou		0	0,99	2	
13	4 Mou		0	0,99	3	
14	4 Mou		0	2	4	
15	4 Units		0	0	5	
16	4 Units		0	0,4	6	
17	4 Data		50	1	7	
18	4 Mou		0	3	8	
19	4 Units		0	2	9	
20	4 Data		0	7	10	

Amount from Tari... Regular Price: (bla...

D\_CUSTOMERS

D\_TARIFF\_PRICES

D\_CALL\_MIXES

F\_USAGE\_MONTHLY

D\_MONTHS

D\_CONTRACTS

D\_TARIFF\_MODELS

Record: 1 of 51

*Slika 17, Definiranje mjera*

Formula nam osigurava da svaki puta kada pokušamo dohvatiti mjeru, ukoliko nismo dovoljno detaljno napravili drill-down i odabrali točno jedan redak, mjera neće vratiti ništa. Ovime smo se osigurali od krive interpretacije podataka. Kod mjera, koristili smo jednostavniju formulu koja jednostavno računa prosjek:

MONT...	CONTRAC...	TARIFF_MODE...	MOU	UNITS	DATA_VOLUME	CALL_MI...	Add Column
201301	846502628	2	37,783...	38	0	2	
201304	846502628	2	0	23	0	6	
201308	846502628	2	136,21...	94	0	1	
201309	846502628	2	0	74	0	5	
201401	846502628	2	94,116...	93	0	1	
201402	846502628	2	77470,...	457	1291,344126701...	7	
201402	846502628	2	5,25	6	0	3	
201403	846502628	2	0	18	0	6	
201403	846502628	2	0	46	0	5	
201404	846502628	2	0	49	0	5	
201404	846502628	2	81213,...	510	1733,458352088...	7	
201302	9779201	2	249,13...	226	18,99697971343...	7	
201305	9779201	2	33,1	43	0	2	
201401	9779201	2	0	35	0	6	
201405	9779201	2	0	18	0	5	
201405	9779201	2	0	90	0	6	
201303	3042798	2	1,5833...	1	0,160299301147...	7	
201305	3042798	2	124,26...	78	0	2	
201308	3042798	2	5851,9...	579	29,58049774169...	7	
201309	3042798	2	149,4	103	0	2	

Slika 18, Prikaz mjera

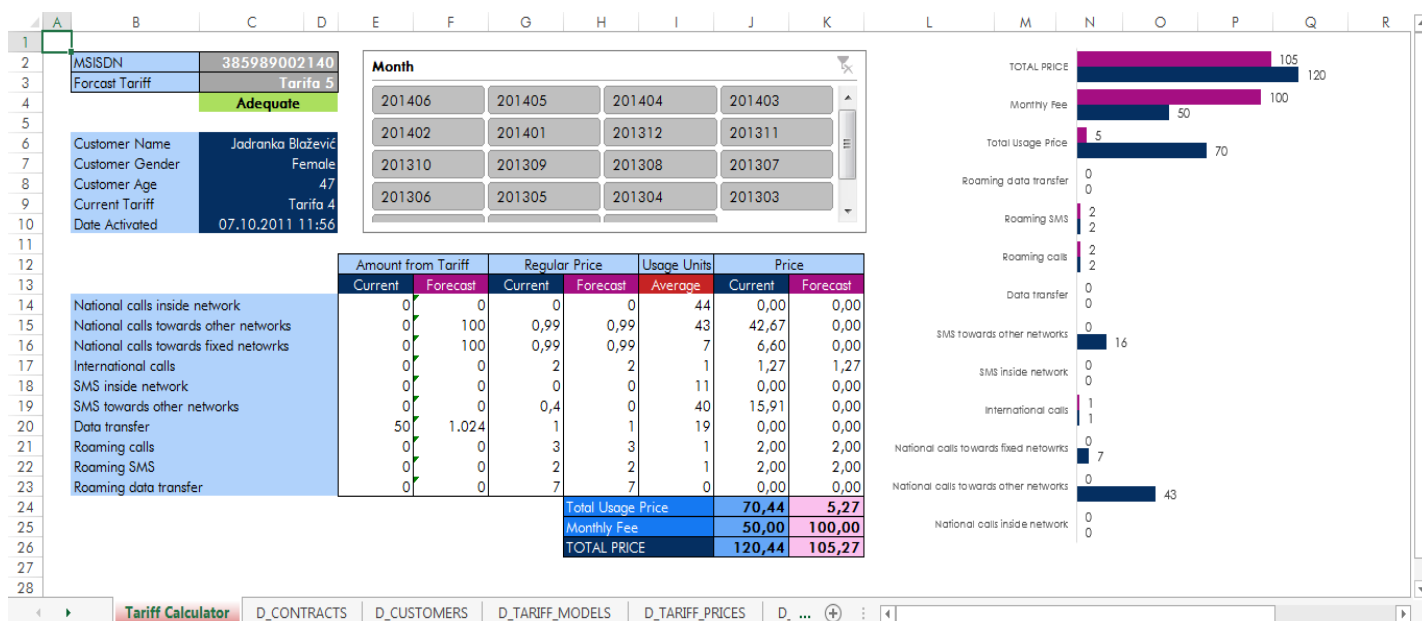
Dobra stvar kod Powerpivot-a je što se prema ovom modelu, kao i cjelokupnom izvoru podataka, ponaša kao da se radi o OLAP kocki. Time nam omogućava da kroz običnu „pivot“ tablicu vidimo da li je model dobro definiran te vraća li očekivane vrijednosti. Također, što je bitnije, možemo koristiti i sve funkcije namijenjene kockama. Na osnovu nekih od tih funkcija temelji se i naše rješenje. Potrebno je dohvatiti određene mjere i određene vrijednosti pojedinih dimenzija. Kao idealno rješenje koje omogućava stopostotnu slobodu kod kreiranja izvještaja koristili smo:

- CUBEVALUE – funkcija koja dohvaća mjeru iz kocke na osnovu predanih filtera
- CUBEMEMBER – funkcija koja dohvaća određenu vrijednost dimenzijskog atributa ili pak metapodatke vezane za određenu mjeru ili atribut

Konačan cilj je omogućiti prodajnim predstavnicima odabir nekog od korisnika, te uvid u isplativost tarifa koje imamo u portfelju za korisnika na osnovu njegove potrošnje.

Finalni izvještaj (dashboard koji se može objaviti na nekom portalu ili zasebno prikazivati u Excelu) sastoji se od dva polja za unos te jednog slicer-a:

- MSISDN – ovime odabiremo korisnika na osnovu njegovog broja
- Tarifa – ovime odabiremo tarifu za koju bi željeli vidjeti da li je isplativa korisniku
- Mjesec – možemo izabrati varijabilni period na osnovu kojeg radimo analizu

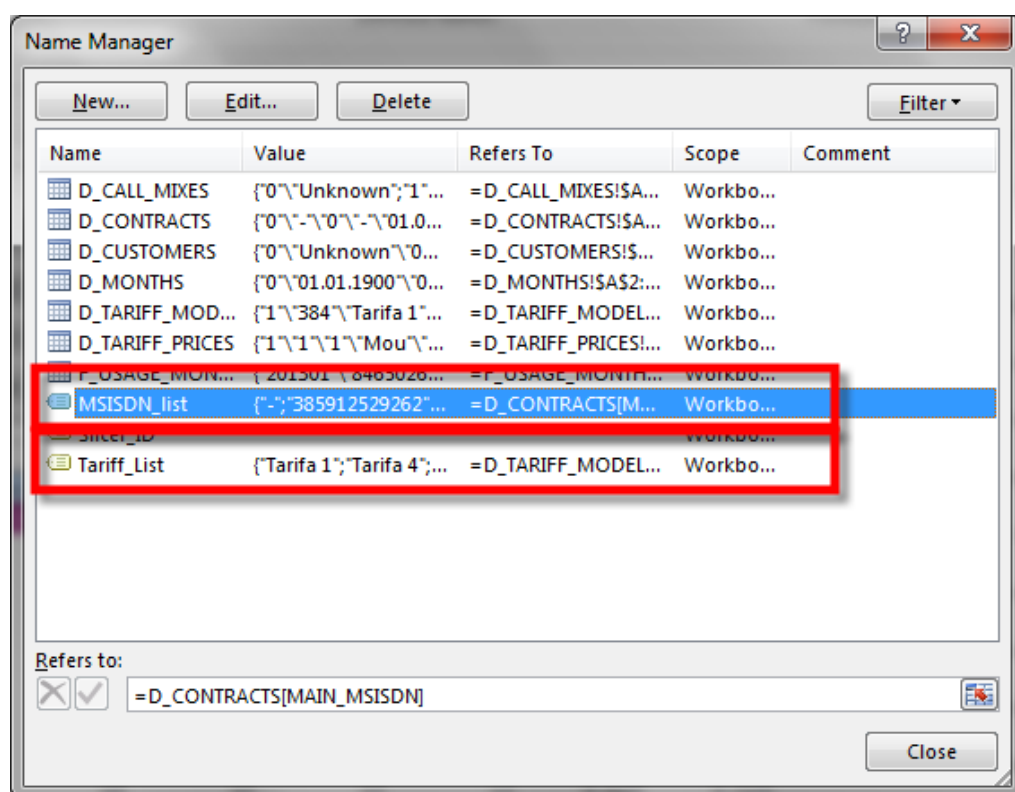


Slika 19, Prikaz tarifnog kalkulatora

Izvještaj se sastoji od 2 načina prikaza sličnih podataka. Grafički prikaz nam jasno pokazuje u kojim segmentima je nova tarifa bolja ili lošija za korisnika, dok u tabličnom prikazu imamo više podataka za čije tumačenje moramo potrošiti više vremena. Ovdje imamo cijene za trenutnu i odabranu tarifu, iznos potrošnje uključene u tarifu, te cijene po pojedinom tipu potrošnje. Kao finalne informacije nudi se usporedba mjesečnog računa za korisnika, i na jednostavan način pomoću formula i kondicionalnog formatiranja ispisujemo i formatiramo poruku o isplativosti odabrane tarife za krajnjeg korisnika. Ako je iznos mjesečnog računa za odabranu tarifu manji od iznosa koji je korisnik plaćao na osnovu svoje tarife, prikazuje nam se oznaka da je ponuda adekvatna:



Padajući izbornici koji omogućavaju jednostavnu interakciju prodajnog predstavnika s alatom riješeni su preko „Data validation“ opcije u Excelu. Prethodno smo definirali listu tarifa i listu MSISDN-ova koje prodajni predstavnik može odabrati.



Slika 22, Data validation

## 6 ZAKLJUČAK

Vremena se drastično mijenjaju. Danas je izuzetno teško imati konkurentnu prednost. Poduzeća koja žele uspjeti u budućnosti su ona koja mogu brzo djelovati sa informacijama koje raspolažu. To je novo viđenje poslovne informacije. Problem nije nedostatak informacija, nego što većina tvrtki ne koristi informacije kojima raspolažu na njihov najbolji mogući način. Osim toga, tvrtke trebaju smanjiti rok od trenutka kad su prikupili informacije do trenutka kada djeluju sa njom. Onaj koji ne uspije djelovati sa informacijom u kratkom roku može imati ozbiljne posljedice.

Skladištenje podataka i poslovna inteligencija su neizostavni alati u telekomunikacijskoj industriji koji im pomažu sačuvati stare i dobiti nove korisnike, razviti nove usluge, te smanjiti troškove i povećati prihode. Kako je implementiranje skladišta podataka i poslovne inteligencije dug i zahtjevan posao, neki telekomunikacijski operateri nisu otvoreni u tom smjeru. Obično se tada pokušavaju prikupljati podaci alternativnim putevima koji se nakon nekog vremena pokazu netočnima.

U današnje vrijeme ekonomske krize, svaki korisnik je bitan. Uz skladište podataka i poslovnu inteligenciju možemo upoznati naše korisnike, ponuditi im uslugu koja će im se svidjeti i zbog koje će ostati kod postojećeg operatera.

## 7 LITERATURA

D.Pareek, *Bussinessintelligence for telecommunications*, AuerbachPublications, New York, 2007.

C. Adamson, *Star Schema*, TheMcGraw-HillCompanies, New York, 2010.

R.Kimball, M. Ross, *RelentelesslyPracticalTools for Data WarehousingandBusinessIntelligence*, WileyPublishingInc., Indianapolis, 2010.

E. Turban, R. Sharda, D. Delen, D. King,*BusinessIntelligence*, Second Edition. PrenticeHall, 2010.

## 8 SAŽETAK

Skladištenje podataka i poslovna inteligencija veoma su važni alati u telekomunikacijskoj industriji. Ovaj rad daje pregled ključnih riječi skladištenja podataka i poslovne inteligencije, te su objašnjeni osnovni pojmovi poput dimenzijskih tablica i vrsta poslovne inteligencije. Također, u radu je opisan tarifni kalkulator koji prikazuje koja tarifa je korisniku najisplativije. Pokazano je da su ova dva alata neophodna u telekomunikacijskoj industriji jer između ostalog, smanjuju troškove i povećavaju prihode, što je u vrijeme ekonomske krize i više nego potrebno.



## 9 SUMMARY

Data Warehousing and Business Intelligence are very important tools in telecommunications. This work provides an overview the keywords of data warehousing and business intelligence, and explaining basic expression ssuch as dimensional tables and types of business intelligence. Also, this work describes the tariff calculator which shows the most economical tariff for the user. It has been shown that these two tools are essential at telecommunication industry because, among other things, they help to reduce costs and increase revenues in time of economic crisis when it is more than important.

## 10 ŽIVOTOPIS

Rođena sam 17.12.1987. godine u Zagrebu, gdje sam nakon završene osnovne i srednje škole upisala Prirodoslovno – matematički fakultet, matematički odsjek.

Za sebe volim reći da sam veoma svestrana. Volim sport te se odmalena bavim veslanjem, bez kojeg ne bih bila gdje sam danas. Ponosna sam vlasnica brončane medalje sa Europskog sveučilišnog prvenstva u veslanju koje se 2006. godine održavalo u Briveu u Francuskoj. Također, pet godina vodila sam žensku veslačku ekipu VKPMF te u to vrijeme ženska ekipa je osvojila brojne medalje među kojima su dva zlata sa studentskog sveučilišnog prvenstva u veslanju koje se održavalo u Zagrebu.

Tokom fakulteta sam se učlanila u studentsku udrugu eSTUDENT te sudjelovala u organizaciji studentskog natjecanja u rudarenju podataka pod nazivom Mozgalo. .

Također, dobila sam praksu u Allianz, u sektoru neživotnog osiguranja.

Na natjecanju „Iskustvo zlata vrijedi“ koje je nudilo praksu u Vipnetu u odjelu kontrolinga osvojila sam drugo mjesto. No, to me nije obeshrabrilo, te sam se još više htjela pokazati na svom studentskom poslu u Vipnetu, u odjelu IT Billinga. Moj trud se prepoznao te sam od drugog mjeseca 2014. godine tamo zaposlena kao stručnjak za naplatu usluga (eng. *RatingSpecialist*).